

DOI:10.19651/j.cnki.emt.2415618

室内障碍物点云分割的可变阈值联合聚类算法研究^{*}

刘洪凯 王少红 左云波 谷玉海

(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: 激光雷达点云分割技术在智能车辆环境识别中扮演着重要角色。由于激光雷达存在点云近密远疏、分布不均匀的问题以及存在噪点的情况,导致出现点云分割不准确的现象。针对上述问题,提出了一种可变阈值联合聚类算法。该方法首先对点云数据进行预处理,使用直通滤波、体素滤波和立方体滤波对点云进行提取、稀疏和降噪,再联合自适应DBSCAN算法和改进后的可变阈值欧式聚类算法对点云进行聚类分割。采集真实场景数据进行测试,结果显示,在C-H系数、轮廓系数、D-B系数及轮廓系数等评价指标上均有所提高。这表明,可变阈值联合聚类算法显著提高了点云分割的准确性,有效的提高了聚类结果的类内一致性和类间差异性,为目标检测和识别提供了更可靠的基础。

关键词: 激光雷达;障碍物检测;点云分割;DBSCAN

中图分类号: TN959.5;TP393 **文献标识码:** A **国家标准学科分类代码:** 080200

Research on variable threshold joint clustering algorithm for indoor obstacle point cloud segmentation

Liu Hongkai Wang Shaohong Zuo Yunbo Gu Yuhai

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

Abstract: Lidar point cloud segmentation technology plays an important role in intelligent vehicle environment recognition. Due to the problems of near dense and far sparse point clouds, uneven distribution, and the presence of noise in LiDAR, inaccurate point cloud segmentation occurs. A self adaptation DBSCAN with Euclidean joint clustering algorithm is proposed to address the above issues. This method first preprocesses the point cloud data, using through filtering, voxel filtering, and cube filtering to extract, sparse, and denoise the point cloud. Then, it combines the adaptive DBSCAN algorithm and an improved variable threshold Euclidean clustering algorithm to cluster and segment the point cloud. Real scene data was collected for testing, and the results showed improvements in evaluation indicators such as C-H coefficient, contour coefficient, D-B coefficient, and contour coefficient. This indicates that the variable threshold joint clustering algorithm significantly improves the accuracy of point cloud segmentation, effectively improves the intra class consistency and inter class differences of clustering results, and provides a more reliable foundation for object detection and recognition.

Keywords: LiDAR; obstacle detection; point cloud segmentation; DBSCAN

0 引言

激光雷达具有较高的测量准确性、较大的探测范围以及不受光照条件影响的抗干扰能力,这些优势使其成为了环境感知领域的一项关键技术,在智能驾驶、移动机器人等领域得到广泛的应用^[1]。在三维激光雷达点云处理中,点云分割是其中至关重要的一个环节,要实现对外环境中

目标的分类与识别,首先是要实现点云分割,为后续的目标分类或目标识别奠定基础,点云分割的效果会直接影响后续的处理过程。因此,大量学者开展了对点云分割算法的研究。

近年来,国内外学者们对激光雷达点云分割方法的研究主要集中在两个方向:基于深度学习^[2]和基于点云聚类^[3]。前者是使用数据集训练模型,使用训练好的模型进

收稿日期:2024-03-12

^{*} 基金项目:国家重点研发计划(2020YFB1713203)项目资助

行点云分割^[4]。Cheng等^[5]基于区域内结构学习模块(intra-region structure learning, ISL)和区域间关系学习模块(inter-region relation learning, IRL)构建了区域间关联性自适应提取网络模型;Hu等^[6]使用随机采样和局部特征整合模块(local feature aggregation, LFA)建立了高效特征提取网络模型;李云飞等^[7]提出了一种基于改进PointNet++的室内点云语义分割模型,利用中垂线通道采样获取采样点,使用采样点邻域特征自适应分组,引入注意力机制,提高了对室内点云语义分割的整体准确率。基于深度学习的点云分割方法有以下优势:分割精度高和主观性低的特征提取。但必须提前使用数据集进行训练,且制作数据集的过程比较麻烦;并且数据集质量和数据集场景与实际场景的不同也会直接影响模型的分割效果;此外,深度学习对计算的硬件要求较高。

由于深度学习网络计算需要进行大量数据训练,耗费巨大的计算资源,因此在很多无人车应用场合仍然使用传统的基于特征的分割算法,其可分为4种方法:基于聚类、基于模型拟合、基于边缘和基于区域增长的方法^[8]。其中,模型拟合的随机采样一致性(random sample consensus, RANSAC)算法不适用于不规则障碍物的分割,为此李佳佳^[9]等提出了一种改进的RANSAC算法,根据法向量提取地面,设置高程阈值去除非地面点,然后使用最远点采样(farthest point sampling, FPS)获取种子点拟合平面;王江等^[10]提出了一种动态滑动窗口的方法提取路沿特征点,再使用RANSAC进行路沿直线拟合。为了增强聚类算法适用性,众多学者开展多指标融合聚类算法研究。例如,Zheng等^[11]融合基于相对距离和密度的聚类算法,能够对密度不均匀的点云进行有效聚类分割。范晶晶等^[12]基于欧式聚类和行人的几何特征构建了识别行人的框架,但未考虑行人的连续变化及噪声点这两个影响因素;Chen等^[13-14]在基于密度的噪声应用空间聚类算法(density-based spatial clustering of applications with noise, DBSCAN)中加入block的概念,在簇生长的过程中处理多个点云,减少了算法耗时,但未考虑局部密度变化会影响聚类效果;Zhang等^[15]中提出了一种路侧雷达的背景滤除和目标检测框架,使用DBSCAN算法提取点云前景目标,但未考虑目标距离的不同会影响聚类效果;杨建华等^[16]通过划分区域及阈值自适应的方式改进欧氏聚类算法,但对路面小障碍物检测效果欠佳。

上述文献大多数没有考虑因目标距离雷达不同而易产生欠分割和过分割的情况,针对此问题,基于传统的DBSCAN算法和欧式聚类算法,提出一种可变阈值联合聚类算法(self-adaption DBSCAN with euclidean, SADWE)。首先对原始点云数据进行预处理,包括采用体素滤波方法稀疏点云、直通滤波方法去除地面和立方体滤波方法降噪,再联合自适应DBSCAN算法和改进后的可变阈值欧式聚类算法分割障碍物。最后在室内采集点云数据,对联合聚

类算法进行验证。

1 数据预处理

使用1台车载激光雷达VLP-16进行数据采集,16线激光雷达,扫描频率5~20 Hz,垂直测量角度范围:30°(+15°~-15°),垂直方向角度分辨率:2°,水平方向测量角度范围:360°,水平方向角度分辨率:0.1°~0.4°,探测精度3 cm,每秒30万点数,探测距离100 m。通过车载激光雷达获取的点云数据,数据量庞大,需对点云数据进行预处理。

1.1 直通滤波

在雷达点云处理中,直通滤波可以用于去除噪声、提取感兴趣区域和过滤掉无关的点云。直通滤波的过程如图1所示。




图1 直通滤波流程图

保留的点集 P 满足式(1)的要求:

$$\begin{cases} x_i^2 + y_i^2 < r_{Th}^2 \\ x_1 < x_i < x_2 \\ y_1 < y_i < y_2 \\ z_1 < z_i < z_2 \end{cases} \quad (1)$$

式中: (x_i, y_i, z_i) 为点集 P 中某点的三维坐标; r_{Th} 为半径阈值, 由于激光雷达的检测范围, 取 $r_{Th} = 50$ m; $x_1, x_2, y_1, y_2, z_1, z_2$ 为的 x 轴、 y 轴和 z 轴方向的选取范围, x 轴方向为车辆前进方向, 取 $x_1 = -50$ m、 $x_2 = 50$ m、 $y_1 = -10$ m、 $y_2 = 10$ m、 $z_1 = -0.8$ m、 $z_2 = 1.0$ m。障碍物目标点云与地面点云相连接, 无法直接通过聚类的方法进行分割, 因此需要去除地面点云。本文默认路面为平面, 并且实验环境选取路面平坦的地区。因此使用直通滤波选取固定高度范围内的点云以达到去除地面的效果, 由激光雷达的安装位置可知, 当设置 $z_1 = -0.8$ m 可以完全去除地面的点云信息。滤波前后的点云如图2、3所示。




图2 原始点云数据




图 3 经直通滤波后的点云数据

1.2 体素栅格滤波

体素栅格滤波是将三维空间分割为三维体素栅格,在每个体素栅格内,用其中所有点的重心占据此栅格。体素滤波可以降低点云的密度,在参数设置合理的情况下能够保持点云的形状特征。对提取的点云进行体素滤波处理,栅格尺寸大小为 $5 \times 5 \times 5$ cm。体素滤波处理前后效果对比如图 4、5 所示。




图 4 体素滤波前点云数据




图 5 体素滤波后点云数据

1.3 立方体滤波

立方体滤波算法基于设定的立方体参数,将位于立方体内的点保留下来,将超出范围的点丢弃,或者将位于立方体内的点丢弃,保留之外的点。激光雷达在扫描周围环境时,由于安装位置的原因,会扫描到一部分车体的点云数据,车体的数据会对后续的点云分割产生一定影响,因此认为这部分的点云信息属于无用的噪点部分,设置立方体的大小为车辆大小,过滤掉车体产生的点云,处理前后效果如图 6、7 所示。




图 6 立方体滤波前点云数据




图 7 立方体滤波后点云数据

2 可变阈值联合聚类算法

2.1 改进 DBSCAN 算法

首先对 DBSCAN 算法进行改进,它基于密度可达性和密度连通性的概念,能够发现具有不同形状和大小的簇,并且对噪声点具有较好的鲁棒性。在 DBSCAN 算法中有两个重要的参数: Eps 和 $MinPts$ 。 Eps 是搜索时的邻域半径, $MinPts$ 为核心点邻域内点数的阈值。其具体的算法过程如图 8 所示。

DBSCAN 在聚类半径固定的情况下,对某些距离远的障碍物聚类效果不好。因此,将聚类半径 Eps 改进为自适应阈值。激光雷达的激光束在空间内的水平向分布和垂直向分布示意图如图 9、10 所示。当激光线束扫在处于不同空间位置的障碍物时,在同一水平面上激光线束近密远疏,垂直方向上中间激光线束密、两边稀疏的特点,导致不同空间位置的点云疏密程度不同,因此,聚类半径 Eps 要依据式(2)进行自适应调整。另外,最少点数 $MinPts$ 选取经验值 5。

$$Eps = \frac{\alpha \pi \Delta \gamma \sqrt{x_i^2 + y_i^2}}{360^\circ} + \beta |z_i| \quad (2)$$

式中: $\Delta \gamma$ 为激光雷达的水平角分辨率; x_i 、 y_i 、 z_i 为空间内第 i 个三维点的坐标值; $|z_i|$ 为对应的高度绝对值; $\alpha = 0.035$ 和 $\beta = 0.25$ 分别为水平方向和垂直方向上的相关系数。

2.2 改进欧式聚类算法

欧式聚类适用于不规则区域的分割,其基于欧式距离

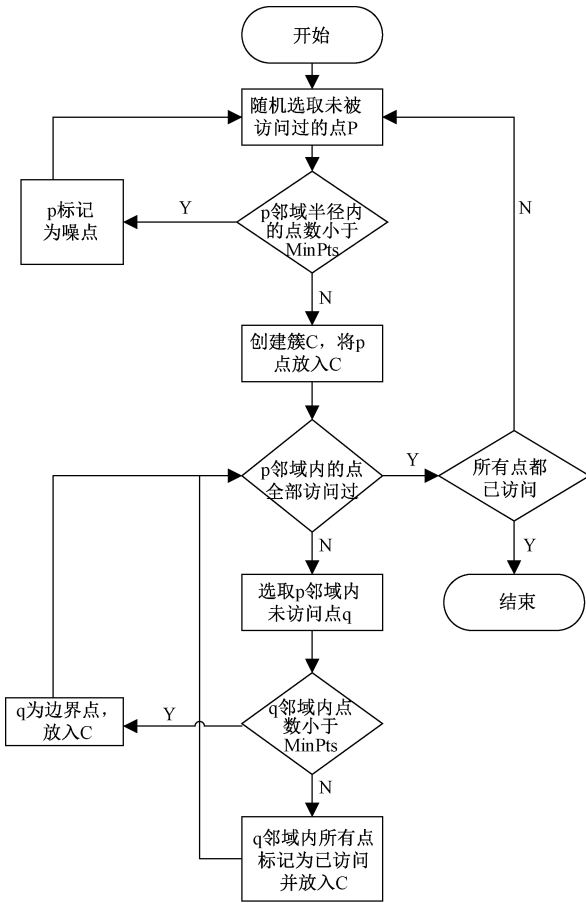


图8 DBSCAN 算法流程




图9 激光束水平方向分布




图10 激光束垂直方向分布

进行度量。具体的流程如图11所示。

通常情况下,距离阈值的设定会参考点间平均距离,点间平均距离为点云中任意点与其最近点的距离的平均值。为了提高算法的准确性和鲁棒性,将欧式聚类过程中的距离阈值设置动态,来避免因使用同一阈值而产生过分割和

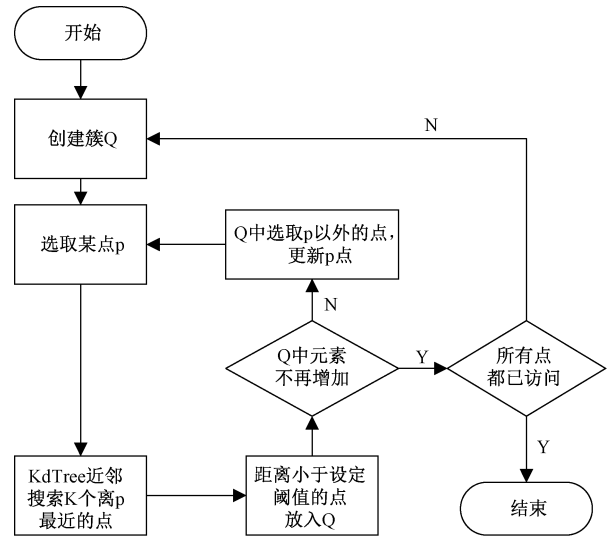


图11 欧式聚类流程图

欠分割的情况。动态阈值可由式(3)求得。

$$d = \alpha \sqrt{x_i^2 + y_i^2} + \beta \quad (3)$$

其中, x_i 和 y_i 为点的坐标; α 和 β 是调整阈值 d 的相关系数,其大小与激光雷达的角分辨率和角精度相关,与角分辨率正相关、与角精度成负相关,具体的取值需通过进行多组实验,对实验数据进行最小二乘拟合来确定。

2.3 融合自适应 DBSCAN 和改进欧式聚类的联合聚类算法

本文提出一种融合上述的自适应 DBSCAN 和改进欧式聚类的联合聚类算法,改进的联合聚类算法首先使用自适应 DBSCAN 算法对点云进行初步聚类,获取高密度的区域,然后从分割出的簇中随机选取种子点进行可变阈值欧式聚类,获取最终分割结果。联合聚类算法的伪代码如算法1所示。

算法1: SADWE

Input: PointsSet, Eps, MinPts

Output: PointsSetWithCLID

```

1: BEGINID=0
2: UNCLASSIFIED=0
3: NOISE=-1
4: ClusterID=nextID(BEGINID)
5: KDTTree=buildKDTTree(PointsSet)
6: for i from 0 to PointsSet.size()-1 do
7:   Point=PointsSet.get(i)
8:   If Point.CLID=UNCLASSIFIED then
9:     adaptEps=adaptThreshold(Point,Eps)
10:    If ExpandCluster(PointsSet,KDTTree,point,
11:      ClusterID, adaptEps, MinPts, UNCLASSIFIED,
12:      NOISE) then
13:      ClusterID=nextID(ClusterID)

```



```
12:         end if
13:         SaEuclideanClustering ( PointsSetWithCLID.
14:         get(ClusterID-1))
15:     end for
16:     return PointsSetWithCLID
```

3 实验结果与分析

3.1 实验数据与环境

为验证联合聚类算法的有效性,利用实验室的履带式无人车采集实验数据,无人车如图 12 所示。数据由 1 台车载激光雷达 VLP-16 采集,激光雷达安装位置如图 12 所示。实验场景为实验室环境。实验运行环境为:Core i7-13700H,16 GB,系统环境 Ubuntu20.04,开发环境为 Ros2-Galactic,编程语言为 C++,利用 rviz2 进行点云可视化。



图 12 履带式无人车

3.2 实验验证

首先是数据预处理过程,通过直通滤波可以去除掉地面部分和过高的部分,去除地面可以保证障碍物之间相互不连通。原始点云每帧约 29 000 个点,经直通滤波后每帧剩余约 15 000 个点,平均点云数量降为 50.88%。通过体素滤波降低点云的密度,可节省计算时间,经过体素滤波处理后每帧剩余约 6 700 个点,平均点云数量降为 23.18%。通过立方体滤波,每帧点云去除约 5~10 个车体产生的噪点。数据预处理前后的效果如图 13、14 所示。




图 13 原始点云数据




图 14 预处理点云数据

最大距离与距离激光的成正比,比例系数为 2 倍 $\tan(1^\circ)$,约等于 0.034 91,可推断出式(3)中 α 的值与该系数相等。通过多次实验设置不同的阈值 d ,通过观察不同范围内的聚类结果确定可行范围,实验数据如表 1 所示。将得到结果进行最小二乘拟合,将其关系拟合为一次方程,得到 α 与 β 的值。即:

$$d = 0.035 \sqrt{x_i^2 + y_i^2} + 0.03 \tag{4}$$

曲线拟合结果如图 15 所示。

表 1 阈值与可行范围对照表

阈值 d	0.1	0.2	0.3	0.4
可行范围	2	5	8	10




图 15 自适应阈值拟合曲线

如图 16 所示为聚类分割前的点云俯视图,对分割出的不同的障碍物采用不同的颜色进行标记,如图 17 所示为整个实验环境聚类分割后的点云俯视图,能够有效的分割出墙体和周围障碍物。图 18 为车体周围的障碍物分割效果,




图 16 非地面点云原始数据

通过激光雷达的角分辨率可以得知点云中相邻两点的




图 17 非地面点云联合聚类结果




图 18 无人车周围障碍物分割效果

对指示牌、椅子、工位、行人等物体能够正确分割,指示牌的具体分割效果如图 19、20 所示,图 21 中从左至右依次为工位、柱子、角柜、行人、椅子。图 22 展示的是对行人分割效果,可以看出即使行人之间距离较近,联合聚类算法也能够对其进行有效的分割。




图 19 指示牌(a)




图 20 指示牌(b)




图 21 多种障碍物分割效果




图 22 行人分割效果

3.3 障碍物检测结果分析

对采集到的 400 帧点云图分别使用 DBSCAN 算法、欧式聚类与本文算法进行聚类分割,从算法耗时、类别数、C-H 系数 (Calinski-Harabasz score)、轮廓系数 (silhouette score) 和 D-B 系数 (Davies-Bouldin score) 5 个指标进行对比分析。

C-H 系数通过计算所有簇间离散度和簇内离散度之和的比值来衡量聚类的紧密性,C-H 系数的值与聚类结果正相关。C-H 系数的计算如式(5)所示。

$$CH = \frac{\text{tr}(B_k)}{\text{tr}(W_k)} \times \frac{n_E - k}{k - 1} \quad (5)$$

式中: $\text{tr}(\cdot)$ 为矩阵的迹; E 为输入数据; n_E 为数据维度; k 为聚类结果中簇的个数。而 W_k 和 B_k 则分别为:

$$W_k = \sum_{q=1}^k \sum_{x \in C_q} (x - c_q)(x - c_q)^T \quad (6)$$

$$B_k = \sum_{q=1}^k n_q (c_q - c_E)(c_q - c_E)^T \quad (7)$$

式中: C_q 为簇 q 的点的集合; c_q 为簇 q 的中心点; c_E 为输入数据 E 的中心点; n_q 为簇 q 大小。

轮廓系数的大小可由式(8)计算得出, a 是簇内任意一点到簇内其他点距离的平均值, b 是簇内任意一点到相邻簇内所有点距离的平均值,其取值范围为 $[-1, 1]$,与聚类效果呈正相关。

$$s = \frac{b - a}{\max(a, b)} \quad (8)$$

D-B 系数通过计算簇间距离与簇所占空间的比值来衡量簇的平均相似性。D-B 系数与聚类效果呈反相关。D-B 系数的算法如式(9)所示。

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} R_{ij} \quad (9)$$

式中: DB 为 D-B 系数; $i = 1, 2, \dots, k$ 为聚类结果中簇的下标; 簇 j 为与簇 i 最相似的簇。 R_{ij} 的算式为:

$$R_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (10)$$

式中: s_i 为簇 i 内所有点到簇的中心点的距离的均值, s_j 同理; d_{ij} 为簇 i 和簇 j 的欧氏距离。

算法在每一帧数据中的表现如图 23~27 所示。由图 23 可知欧式聚类耗时在 20~40 ms 之间, DBSCAN 算法耗时在 30~60 ms 之间, 本文算法耗时在 60~100 ms 之间, 联合自适应的 DBSCAN 算法和欧式聚类的算法耗时增加, 约为二者耗时之和。从图 24 可以看出本文算法的簇的数量明显减少, 其原因为采取自适应策略后, 对于距离较远、点云稀疏的数据有更大的阈值, 使之前属于同一类而未能聚到一簇的点云聚为一类, 有效的解决了远距离过分割的现象。从图 25 可知, 联合聚类的 C-H 系数略高于欧式聚类, 但低于 DBSCAN 算法。而从图 26 可以看出联合聚类算法的轮廓系数明显高于欧式聚类, 并且在约 80% 的情况下略高于 DBSCAN 算法。由图 27 可知, 本文算法在 D-B 系数上明显低于其他两种算法, 所有帧的 DB 均值均为 DBSCAN 的 28.5%, 欧式聚类的 45.3%。从后 3 个系数的变化可以看出, 联合聚类算法能够结合 DBSCAN 算法和欧式聚类的优势, 并且在类间差异性上优于两种算法, 因此分




图 23 算法耗时对比




图 24 算法类别数对比




图 25 算法 C-H 系数对比




图 26 算法轮廓系数对比




图 27 算法 D-B 系数对比

割出的点云簇有更好的类间差异性和类内一致性, 分割效果有所提升。

3.4 对比分析

如表 2 所示, 对联合聚类算法与其他效果好的算法进行了对比, 包括原 DBSCAN 算法、Zhang 等^[17]提出的 KNN-DBSCAN 算法、传统欧式聚类算法和姚绍华等^[18]改进的 MRC 欧式聚类算法。从表 2 中可以看出 SADWE 算法在后 4 项上评估指标上都优于 MRC 欧式聚类, 在簇的数量均值、D-B 系数均值上优于改进的 KNN-DBSCAN, 但在轮廓系数均值和 C-H 系数均值上略低于 KNN-DBSCAN, 在平均耗时上均高于两种算法。SADWE 算法联合了两种聚类方式, 因此计算量变大, 耗时要高于另外两

种算法。由于本文算法采取了参数自适应策略,因此对于远距离目标有较大的阈值,能将本是一类的点云聚到同簇,更好的处理了过分割现象,簇的数量合理性优于 KNN-DBSCAN 和 MRC 欧式聚类。SADWE 算法采取的策略是对自适应 DBSCAN 算法的簇进行自适应欧式聚类,通过密度聚类能够分割出高密度区域并且能够去除簇周围散落的

点云,减少噪点,使簇的边缘轮廓更平滑,因此联合聚类算法有更好的轮廓系数和 D-B 系数,分割结果与真实的障碍物几何形状相似度有所提高。而在 C-H 系数的表现上介于两者算法之间。综上所述,SADWE 算法在室内障碍物分割上有更好的效果,分割结果轮廓明显,类别数更加准确,为后续障碍物的语义分割提供更高的价值。

表 2 不同算法对比

算法	平均耗时/ms	类别均值	DB 均值	s 均值	CH 均值
DBSCAN 算法	49.79	119.25	44.06	-0.001 479	3 767.45
KNN-DBSCAN	56.78	94.41	34.11	-0.001 316	3 588.76
传统欧式聚类	23.47	34.75	27.76	-0.004 973	3 026.50
MRC 欧式聚类	71.62	31.13	17.69	-0.004 457	2 202.71
SADWE 算法	76.53	28.12	12.58	-0.001 413	3 221.75

4 结 论

本文中主要考虑了激光雷达的工作原理及采集到的点云数据的特点,针对目标距离不同对聚类结果产生的影响,提出了一种基于自适应 DBSCAN 算法和改进欧式聚类的联合聚类算法。然后搭建无人车数据采集平台,采集实验室真实环境数据,对提出的联合聚类算法进行实验验证,结果表明:1)针对原始点云数据,首先使用直通滤波提取出障碍物区域,再使用体素滤波降低点云密度、立方体滤波去除车体本身产生的噪点。通过点云预处理,能够有效的提取出非地面点云,并且降低了点云密度,减少后续算法的计算量,提高了算法的运算效率。2)激光雷达点云数据具有近密远疏的特点,通过设置自适应阈值能够使不同目标有不同的聚类阈值,使其聚类效果更好。通过联合两种聚类方式,能够结合两种算法的优势,有效的处理了远距离过分割现象,类别数更合理,分割种类更准确,同时分割结果轮廓更加明显,有效的提高了聚类结果的类内一致性和类间差异性。此外,本文算法仍存在一些缺陷,比如计算量的增大导致算法耗时增加,自适应的阈值选取拟合为线性,在极近距离和超远距离上效果未达到预期效果。在后续的研究中可以利用 GPU 进行耗时优化以及使用非线性函数拟合自适应阈值。并且激光雷达安装位置的不同、场景的不同等,都会对算法的效果产生影响,因此环境变化导致的算法适用性问题仍然需要深入研究。

参考文献

[1] HUANG L W, CHEN S Y, ZHANG J F, et al. Real-time motion tracking for indoor moving sphere objects with a LiDAR sensor [J]. Sensors, 2017, 17 (9):

1932-1932.
[2] 赵佳琦,周勇,何欣,等.基于深度学习的点云分割研究进展分析[J].电子与信息学报,2022,44(12):4426-4440.
[3] 王子洋,李琼琼,张子蕴,等.应用于无人驾驶车辆的点云聚类算法研究进展[J].世界科技研究与发展,2021,43(3):274-285.
[4] 李娇娇,孙红岩,董雨,等.基于深度学习的3维点云处理综述[J].计算机研究与发展,2022,59(5):1160-1179.
[5] CHENG S L, CHEN X W, HE X W, et al. PRA-Net: Point relation-aware network for 3D point cloud analysis[J]. IEEE Transactions on Image Processing, 2021,30:4436-4448.
[6] HU Q, YANG B, XIE L, et al. Randla-Net: Efficient semantic segmentation of large-scale point clouds[C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020, 11105-11114.
[7] 李云飞,张巧芬,王桂棠,等.基于改进 PointNet++的室内点云语义分割模型[J].国外电子测量技术,2023,42(12):63-69.
[8] RUAN X, LIU B. Review of 3D point cloud data segmentation methods [J]. International Journal of Advanced Network, Monitoring and Controls, 2020,

- 5(1):66-71.
- [9] 李佳佳,李永强,杨亚伦. 基于改进 RANSAC 算法的车载 LiDAR 地面点云提取[J]. 河南工程学院学报(自然科学版),2022,34(1):49-54.
- [10] 王江,金永,姚慧栋. 基于固态激光雷达的道路边沿与障碍物检测[J]. 国外电子测量技术,2023,42(1):138-143.
- [11] ZHENG L X,ZHANG P,TAN J, et al. The obstacle detection method of UAV based on 2D lidar[J]. IEEE Access,2019,7:163437-163448.
- [12] 范晶晶,王力,褚文博,等. 基于 KDTree 树和欧式聚类的越野环境下行人识别的研究[J]. 汽车工程,2019,41(12):1410-1415.
- [13] CHEN Y W,ZHOU L D,WANG C, et al. BLOCK-DBSCAN: Fast clustering for large scale data [J]. Pattern Recognition,2021,109:10762.
- [14] CHENG Y W,ZHOU L D,PEI S W, et al. KNN-BLOCK DBSCAN: Fast clustering for large-scale data [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems,2019,51(6):1-15.
- [15] ZHANG Z Y,ZHENG J Y,XU H, et al. Automatic background construction and object detection based on roadside LiDAR[J]. IEEE Transactions on Intelligent Transportation Systems, 2019,21(10):4086-4097.
- [16] 杨建华,赵轩,郭全民,等. 基于路侧激光雷达的障碍物目标检测方法[J]. 国外电子测量技术,2023,42(1):13-19.
- [17] ZHANG R,DU T,QU S N, et al. Adaptive density-based clustering algorithm with shared KNN conflict game[J]. Information Sciences,2021,565:344-369.
- [18] 姚绍华,贺松,涂园园. 基于改进欧式聚类的三维激光雷达点云目标分割方法[J]. 智能计算机与应用,2021,11(10):73-76.

作者简介

刘洪凯,硕士研究生,主要研究方向为无人车的多传感器融合建图、定位与导航等。

E-mail:2460439865@qq.com

王少红(通信作者),博士,副研究员,硕士生导师,主要研究方向为测控技术、智能诊断与预测维修技术。

E-mail:wangsh78@126.com

左云波,博士,副研究员,硕士生导师,主要研究方向为机电系统智能感知与控制。

E-mail:zuoyunbo@126.com

谷玉海,博士,副研究员,硕士生导师,主要研究方向为机电系统智能感知与控制。

E-mail:guyuhai@bistu.edu.cn