

## 基于二维激光雷达的自适应阈值聚类分割方法

王祝<sup>1,2</sup>, 王智<sup>1,2\*</sup>, 张旭<sup>1,2</sup>, 崔璨<sup>1,2</sup>, 王健<sup>1,2</sup><sup>1</sup>北京交通大学理学院, 北京 100044;<sup>2</sup>北京交通大学发光与光信息技术教育部重点实验室, 北京 100044

**摘要** 二维激光雷达广泛应用于室内障碍物检测中,而障碍物的聚类分割是环境感知中的关键技术。环境特征的复杂性和数据密度分布的不均匀性,导致传统聚类方法无法同时对不同距离、不同类型的障碍物实现良好聚类,容易发生漏检和误检。针对室内障碍物的检测需求,分析了激光雷达的数据特点和室内环境的几何特征,提出了一种改进的基于距离和障碍物特征的自适应阈值聚类分割方法,将阈值调整为随目标距离和类内密度变化的自适应参数。在基于激光雷达的智能车感知系统上进行了复杂障碍物的聚类分割实验,结果表明,相比传统方法,本方法可以明显改善不同距离、不同类型障碍物的聚类分割效果,分割准确度可达到 92.23%。

**关键词** 遥感; 激光雷达; 障碍物检测; 聚类分割; 基于密度的含噪声应用空间聚类; 线性阈值法

中图分类号 TN958.98

文献标志码 A

doi: 10.3788/CJL202148.1610005

## 1 引言

近年来,无人驾驶和移动机器人环境感知技术成为人们的研究热点,而障碍物检测是无人运动平台环境感知系统的关键技术<sup>[1]</sup>。常见的障碍物检测方法包括基于相机和激光雷达两种传感器的检测方法<sup>[2]</sup>。其中,相机易受背景光、阴影等光照条件的影响,且障碍物的深度信息获取比较复杂,实时性不高。而激光雷达可直接获取障碍物的深度信息,不易受外界条件影响,测距精度高、实时性好,适用于障碍物检测领域<sup>[3]</sup>。要实现环境障碍物检测,需将激光雷达数据聚类分割成独立的子集,每个子集与实体障碍物相对应,为后续的障碍物识别追踪提供基础<sup>[4]</sup>。点云分割可依据点云原有及衍生的特征信息将目标点云数据划分为多个有意义的部分<sup>[5]</sup>,在障碍物检测中具有重要的应用价值。

国内外学者对应用于障碍物检测场景的激光雷达数据聚类分割方法进行了大量的研究。Birant 等<sup>[6]</sup>提出了一种基于识别核心点、噪声点、相邻簇的基于时空密度的含噪声应用空间聚类(ST-

DBSCAN)方法,但其数据源为海洋数据,具有特殊性。Wang 等<sup>[7]</sup>提出了一种基于扫描线连续约束(SLCC)的优化分割方法。黄钢等<sup>[8]</sup>提出了一种基于搜索代表点的改进 DBSCAN 方法。赵凯等<sup>[9]</sup>提出了一种基于体素格的 DBSCAN(VG-DBSCAN)方法。李昀泽<sup>[10]</sup>提出了一种通过分段阈值确定自适应阈值的分割方法,但分段阈值法依赖实验经验选取。杭义军等<sup>[11]</sup>用以数据极坐标的距离和角度为参数的线性方程确定自适应阈值,但线性阈值法对室内环境下多障碍物随机分布的环境适应性不强。

针对室内障碍物检测数据密度分布不均匀、环境特征复杂的问题,本文基于激光雷达数据特征和室内环境的几何特征提出了一种改进的基于距离与障碍物特征的自适应阈值方法。将阈值调整为随目标距离和类内密度变化的自适应参数,并将该方法与传统聚类分割方法进行对比分析。基于激光雷达的室内外障碍物聚类分割实验结果表明,相比传统方法,本方法可以明显改善不同距离、不同类型障碍物的聚类分割效果。

收稿日期: 2020-12-31; 修回日期: 2021-02-03; 录用日期: 2021-03-01

基金项目: 国家自然科学基金(61571035,61775012)、集成光电子学国家重点联合实验室开放课题(IOSKL2018KF22)、北京市自然科学基金-交控科技轨道交通联合基金(L201021)

通信作者: \*zhiwang@bjtu.edu.cn

## 2 复杂环境下障碍物的信息获取

### 2.1 复杂环境障碍物的特征分析

为分析激光雷达在室内环境中采集到的障碍物数据特征,将激光雷达安装到无人移动平台上,以测量实验室的环境。图 1 为激光雷达检测到的室内障碍物单帧点云图,室内环境的几何特征可分为直线、折线和圆弧,其中,墙体、桌边和柜边等可视为直线;墙角、桌角等可视为折线;圆椅等可视为圆弧。可以发现,在激光数据中,墙体返回的点集特征通常是长且逐渐稀疏的直线,桌角、柜角的点集通常是短而密集的折线,而椅脚的点集数量较少但相对集中。此外,障碍物至雷达中心的距离不同,激光雷达数据的密度也不同。距离激光雷达较近的障碍物得到的扫描点数据分布相对密集,距离激光雷达较远的障碍物得到的扫描点数据分布比较稀疏。因此,设置一个全局分割阈值会导致距离激光雷达较近的数据出现欠分割情况,距离激光雷达较远的数据出现过分分割情况。




图 1 室内障碍物的点云图

Fig. 1 Point cloud diagram of the indoor obstacles

### 2.2 激光雷达数据的采集

目前,环境感知技术常用的激光雷达为旋转机械式激光雷达,发射器和接收器安装在机械旋转装置上,发射激光束并接收激光束在物体表面发生漫反射的反射光,从而计算激光扫描点到雷达中心的距离<sup>[12]</sup>。图 2 为二维激光雷达数据获取的原理,可以发现,二维激光雷达扫描获取的数据具有以下特点。1)扫描的是物体表面信息,激光雷达与扫描点数据之间无其他障碍物,且扫描点附近只有左右的相邻点。2)同一物体表面的采样点间距基本一致,而物体与物体分界处采样点的间距一般会发生明显变化。3)激光雷达的点云数据密度随扫描距离的变化而变化,距离激光雷达越近,数据密度越大,相应

的数据变化程度就越小;反之,则数据密度越小,相应的数据变化程度越大。




图 2 二维激光雷达数据获取的原理

Fig. 2 Principle of the two-dimensional lidar data acquisition

激光雷达采集的原始数据可用雷达的极坐标中心  $O$  表示,对于  $360^\circ$  扫描的激光雷达,扫描一圈包含  $N$  个有序数据,可表示为

$$P = \{(D_i, \theta_i) \mid i = 1, \dots, N\}, \quad (1)$$

式中,  $D_i$  为扫描点到雷达中心的距离,  $\theta_i$  为扫描点到雷达中心的连线和极轴的夹角。在进行聚类分割前,需要对点云数据进行预处理,以剔除有效范围外的不稳定点,并将其余点转换到直角坐标系下。

## 3 基于距离与障碍物特征的自适应阈值聚类分割方法

### 3.1 阈值聚类与 DBSCAN 聚类

阈值聚类的原理是预先设定一个阈值,从而根据相邻点之间的距离与该阈值的大小将点云数据分成 2 类。针对二维激光雷达数据时,阈值聚类的效果非常显著,原因是二维激光雷达数据中同一个物体表面的采样点间距基本一致,而物体与物体分界处采样点的间距一般会发生明显变化,因此,只要设定一个恰当的阈值,该方法就可以达到非常好的聚类效果<sup>[13]</sup>。但激光雷达的数据密度会随扫描距离的变化而变化,因此,使用一个全局阈值时很难进行分割。

分段阈值法根据点到激光雷达中心的距离确定阈值,需要进行大量的实验,且用同一阈值进行分割的数据仍可能出现过分割和欠分割情况。线性阈值法通过以采样点极坐标的距离和角度为参数的线性方程确定阈值,只考虑了距离变化对阈值的影响,没有考虑到环境特征和障碍物空间分布的影响,当环境分布发生变化时会出现失效情况,环境的适应性不强。

DBSCAN 方法是一种经典的基于密度的聚类

方法,其核心思想是密度可达概念<sup>[14]</sup>。该方法将簇定义为密度相连点的最大集合,能自动确定簇的数量,且能在存在噪声的空间中发现任意形状的种类。DBSCAN 方法需要设置两个关键参数:全局邻域半径  $E_{ps}$  和最小近邻个数  $M_{pts}$ 。虽然 DBSCAN 方法能自动确定簇的数量且能发现任意形状的种类,但仍存在一些不足。如对输入参数  $E_{ps}$  和  $M_{pts}$  比较敏感,而该方法在整个聚类过程中又使用了统一的  $E_{ps}$  和  $M_{pts}$ ,当数据分布明显不均匀时,聚类效果较差;且 DBSCAN 方法的搜索范围是全局,时间复杂度较高,而激光雷达扫描点分割障碍物的关键是相邻点<sup>[15]</sup>。

### 3.2 基于距离与障碍物特征的自适应阈值方法

针对 3.1 节中的问题,引入 DBSCAN 方法的簇密度概念改进线性阈值法,提出了一种新的基于距离和障碍物特征的自适应阈值聚类分割方法。既考虑了激光雷达点云数据密度随距离的变化,也考虑了物体的密度分布,提高了 DBSCAN 方法的环境适应性和分割准确性。其中,距离阈值的确定依据激光雷达的距离分辨阈值。图 3 为激光雷达的距离分辨阈值模型,激光雷达的扫描角分辨率为  $\Delta\theta_i$ ,点  $p_{i-1}$  和点  $p_i$  为相邻的两个扫描点, $D_i$  为点  $p_i$  到原点  $O$  的距离, $d_i$  为点  $p_{i-1}$  到点  $p_i$  的距离, $p'_i$  为  $Op_{i-1}$  延长线上的虚拟点, $Op'_i$  的长为  $D_i$ 。设  $p_i p'_i$  的距离  $T_i$  为原始阈值,考虑到激光雷达在测量过程中的精确度,以  $T_i$  为距离阈值并不准确,因此给出一个与距离相关的参数  $u_i$ ,将其与  $T_i$  的乘积作为距离阈值。




图 3 距离分辨阈值的模型

Fig. 3 Model of the distance resolution threshold

基于距离和密度的自适应阈值,计算当前点与上一点的距离是否小于距离阈值。距离阈值  $h_d$  可表示为

$$h_d = u_i T_i, \quad (2)$$

$$D_i = \sqrt{x_i^2 + y_i^2}, \quad (3)$$

$$T_i = \sqrt{2D_i^2 [1 - \cos(\Delta\theta_i)]}, \quad (4)$$

式中,  $x_i$  与  $y_i$  分别为第  $i$  点的横坐标与纵坐标,  $0 < u < 1$  为自适应比例系数,可根据激光雷达的测量精度确定。

如果当前点与上一点的距离小于距离阈值,表明两个点属于同一类;如果大于距离阈值,则计算当前点之前的上一个类的密度。图 4 为激光雷达数据的分布密度,可以发现,同一物体的密度相对均匀。如果物体间的密度发生较大变化,则需判断当前点与当前类密度均值的差值是否明显大于当前类的样本标准差。如果差值为样本标准差的几倍,则当前点的密度发生明显变化,与上一点不属于同一物体;反之,则属于同一类。




图 4 激光雷达的数据分布密度

Fig. 4 Data distribution density of the lidar

密度阈值  $h_p$  可表示为

$$h_p = \bar{d}_k + \eta S_k, \quad (5)$$

$$d_i = \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}, \quad (6)$$

$$\bar{d}_k = \frac{1}{n} \sum_{i=1}^n d_i, \quad n = X_{\text{num}}(C_k), \quad i \in n, \quad (7)$$

$$S_k = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d}_k)^2}, \quad (8)$$

式中,  $k$  为当前类的序号,  $C_k$  为第  $k$  类点集,  $n$  为第  $k$  类点集中点的数量,  $X_{\text{num}}$  为数量统计函数,  $\bar{d}_k$  为第  $k$  类的密度均值,  $S_k$  为第  $k$  类的样本标准差,  $\eta$  为自适应系数。

分割完成后首先剔除只有一两个点的孤立子集,孤立点一般是物体边界扫描产生的噪声和激光雷达扫描的波动,也有可能是只有一两个点的小物体。障碍物距离激光雷达越近,扫描点越密集,越容易产生噪声。而远处的小物体在激光雷达靠近时,扫描点会增多,不会被剔除。因此,剔除与激光雷达距离小于 0.3 m 的数据,不会影响无人平台避障。本方法的具体步骤如下。

1) 输入激光雷达扫描帧数据。

2) 剔除有效范围外的数据,将数据由极坐标下转换到直角坐标系下。

3) 将起始点归入类别 1,从第二个点到最后一个点,判断当前点与上一个点的距离是否大于当前类的距离阈值。如果小于该阈值,则将其归入当前类;否则,判断当前点与上一个点的距离是否大于当前类的密度阈值。如果小于该阈值,则将其归入当



前类;否则,创建新类,将其归入新类。

4) 判断最后一个点与起始点是否小于距离阈值或密度阈值。如果小于,则将最后一类归入第一类;反之,则不归入。

5) 将类内点数目小于 3 或与激光雷达距离小于 0.3 m 的孤立点集设为噪声并剔除。

### 4 实验结果与分析

用搭载二维激光雷达的智能小车采集环境数据,录制环境数据包含室内、室外多种类型、多种分布的障碍物,以充分验证本方法的有效性。实验中采用的激光雷达为 RPLIDAR-A1,测量半径为 12 m,视场范围为 360°,角度分辨率为 1.0°。在 Matlab 中分别用线性阈值法、基于自适应邻域半径改进的 DBSCAN 方法、基于距离和障碍物特征的自适应阈值法(本方法)对采集的连续帧数据包进行聚类,对比不同方法聚类的准确度和聚类时间。在采

集的数据帧中选取具有代表性的一帧数据,对比改进前后不同方法的聚类效果,实验场景如图 5 所示。室内密集障碍物场景下 3 种方法的聚类分割结果如图 6 所示。其中,坐标系为激光雷达本体坐标系,距离较近的点云数据被归为同一个类。线性阈值法根据障碍物数据极坐标下的距离角度参数计算阈值,改进 DBSCAN 方法的邻域半径不再为全局半径,而是随距离变化的自适应半径。



图 5 室内聚类实验的环境

Fig. 5 Environment of the indoor clustering experiment

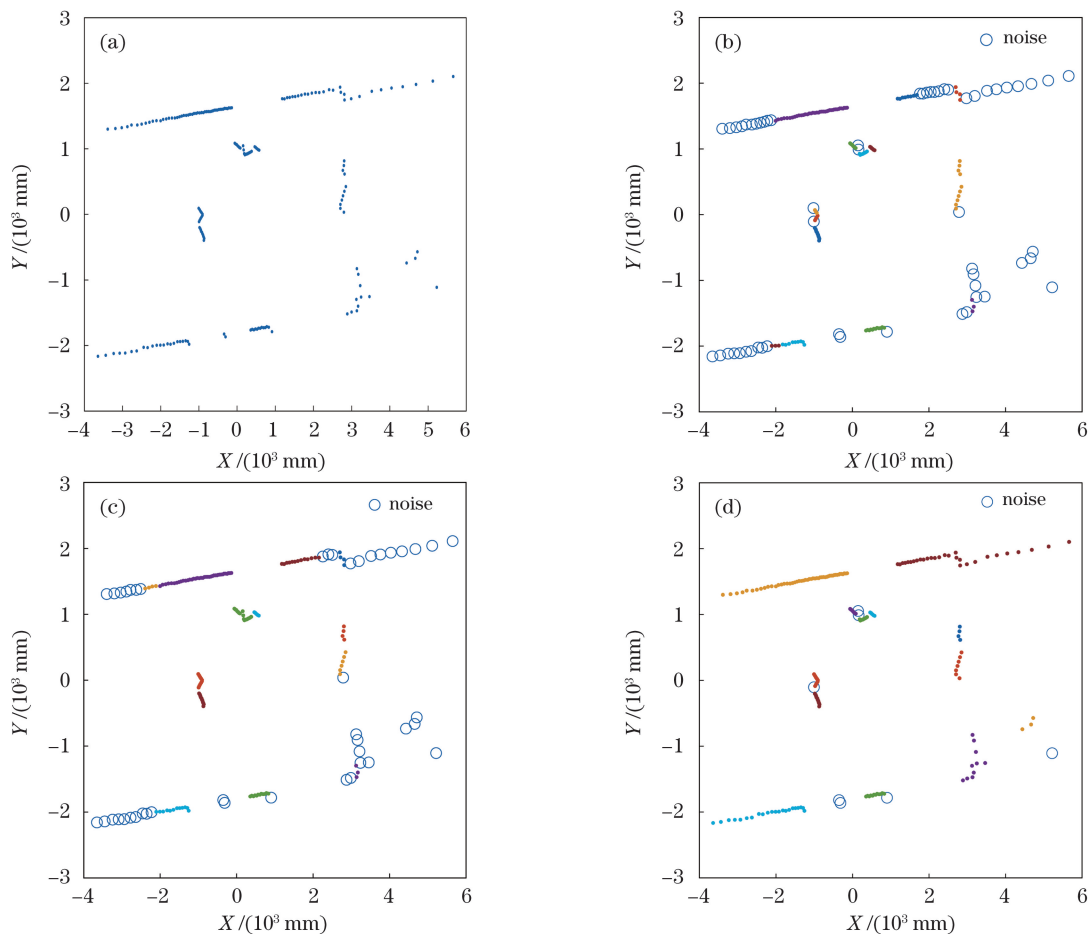


图 6 不同方法的聚类结果(室内)。(a)原始数据;(b)线性阈值法;(c)改进的 DBSCAN 方法;(d)本方法

Fig. 6 Clustering results of different methods (indoor). (a) Original data; (b) linear threshold method; (c) improved DBSCAN algorithm; (d) our method

从图 6(b)可以发现,线性阈值法将距离激光雷达较近( $-1000\text{ mm}, 0\text{ mm}$ )处的 1 个折线形障碍物分割为了 2 个障碍物,而距离激光雷达较远( $2500\text{ mm}, 300\text{ mm}$ )处的 2 个障碍物被聚为 1 类,且( $3000\text{ mm}, 2000\text{ mm}$ )处的墙体数据点被分割为 2 类,还有一部分数据点被误判为噪声。这表明线性阈值法很难对近处的密集点集及远处的稀疏点集实现准确分割。从图 6(c)可以发现,改进 DBSCAN 方法将( $0\text{ mm}, 500\text{ mm}$ )附近 2 个距离较近的折线型障碍物聚类成同 1 类,且将( $3000\text{ mm}, 2000\text{ mm}$ )处的墙体数据点分割为 2 类,还有一部分数据点被误判为噪声,这表明改进 DBSCAN 方法会将间距较近的不同障碍物聚为 1 类。从图 6(d)可以发现,在相同坐标附近,基于距离和障碍物特征的自适应阈值方法在同一距离上能分辨更小的物体间距,对远近数据密度不同的物体也能成功进行分割。这表明当多个障碍物间距较近时,自适应阈值法仍能根据

障碍物密度及其位置自适应找到合适的阈值,从而正确检测出所有障碍物。

室外密集障碍物场景下 3 种方法的实验环境如图 7 所示,分割结果如图 8 所示。其中,距离较近的点云数据被归为同一个类。用不同类型障碍物及墙体和铝板等进一步模拟了室外条件下的直线、折线及曲线等几何特征。



图 7 室外聚类实验的环境

Fig. 7 Environment of the outdoor clustering experiment

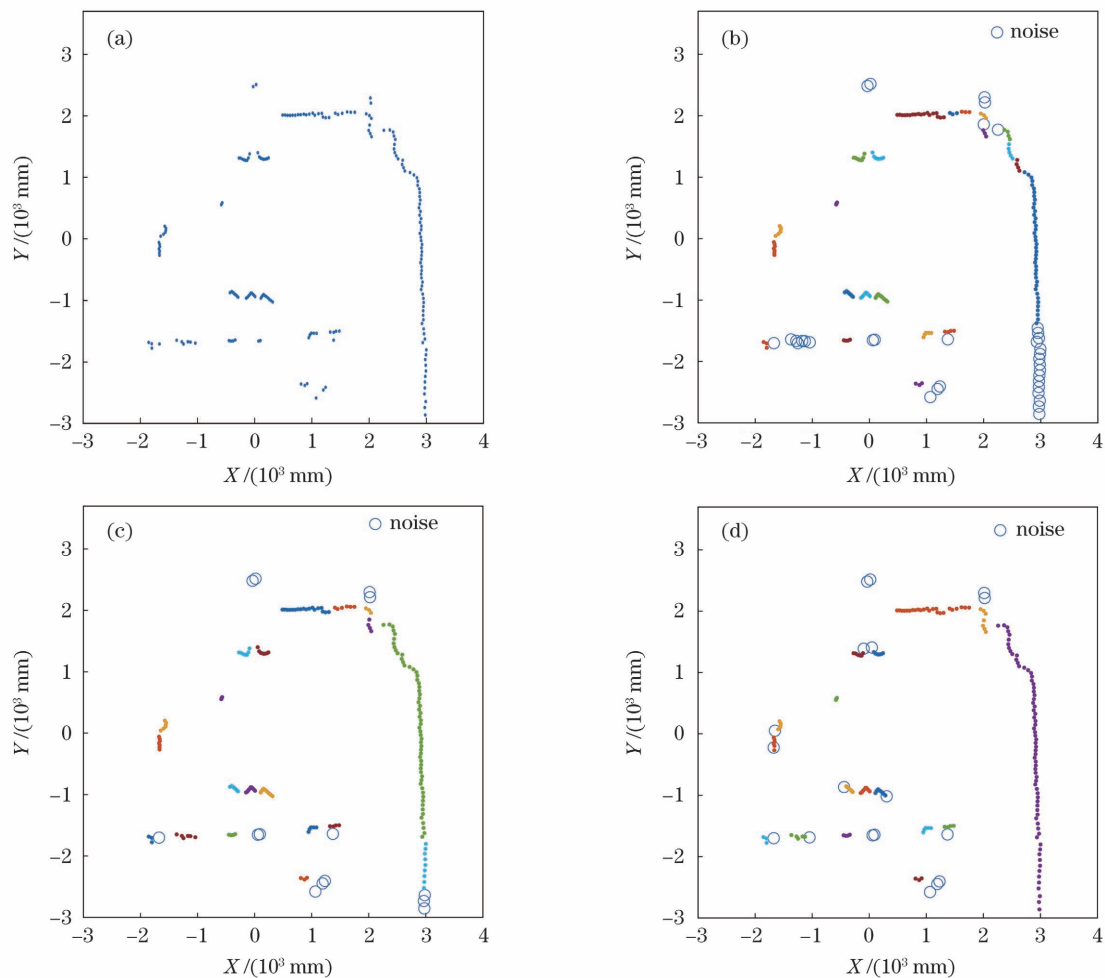


图 8 不同方法的聚类结果(室外)。(a)原始数据;(b)线性阈值法;(c)改进的 DBSCAN 方法;(d)本方法

Fig. 8 Clustering results of different methods (outdoor). (a) Original data; (b) linear threshold method; (c) improved DBSCAN method; (d) our method

从图 8 可以发现,在室外复杂条件下,3 种方法对于近距离处的各类障碍物都能进行成功分割,但对于(3000 mm, -2000 mm)处的连续墙体,线性阈值法将其错误分类为噪声,改进的 DBSCAN 方法则将其错误地分割为 2 类;对于(1500 mm, 2000 mm)处的金属铝板,线性阈值法及改进的 DBSCAN 方法都将其错误地分割为了几类障碍物。而本方法可成功分割出近距离相隔较近的各类障碍物,对于较远

处的墙体与铝板也没有造成过分割,检测精度较高。

分别用 3 种方法对同一时间段的连续帧数据包进行聚类实验,结果如表 1 所示。可以发现,在相同场景下,自适应阈值法的障碍物聚类分割成功率约为 92.23%,相比线性阈值法有明显提高,同时过分割率有明显下降;相比改进的 DBSCAN 方法,本方法的欠分割率有明显下降,且聚类时间与线性阈值法接近。

表 1 3 种聚类方法的性能

Table 1 Performance of 3 clustering methods

Method	Success rate /%	Over segmentation /%	Under segmentation /%	Time(10 frame) /s
Linear threshold method	79.20	13.30	6.44	0.526534
Improved DBSCAN method	85.63	5.28	9.09	1.209348
Ours	92.23	3.23	4.54	0.527302

## 5 结 论

针对激光雷达阈值聚类方法中障碍物远近数据密度不均、障碍物相对位置不均导致的环境适应差、漏检、误检等问题,在分析室内障碍物特征和激光雷达获取数据特点的基础上,引入 DBSCAN 方法中的簇密度概念,改进了阈值聚类法的阈值选取方式。实验结果表明,改进后的聚类分割方法提高了障碍物聚类分割的正检率,相比线性阈值法,本方法的环境适应性更强,能适应更远的环境距离和更小的物体间隔。相比 DBSCAN 方法的全局搜索,本方法的运行时间较短,提高了障碍物检测分割的效率。但在实际环境下,室内外的障碍物十分复杂,本方法的聚类正检率还有待进一步提升。鉴于障碍物的多样性,可以考虑在后续研究中将多传感器融合应用到算法中,进一步提高算法的鲁棒性和稳定性。

### 参 考 文 献

- [1] Kostavelis I, Nalpantidis L, Gasteratos A. Supervised traversability learning for robot navigation [M]// Groß R, Alboul L, Melhuish C, et al. Towards autonomous robotic systems. Lecture notes in computer science. Heidelberg: Springer, 2011, 6856: 289-298.
- [2] Jazayeri A, Cai H Y, Zheng J Y, et al. Vehicle detection and tracking in car video based on motion model[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(2): 583-595.
- [3] Zeng L N. Research on obstacle detection and identification for on-board vision systems [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016.
- [4] 曾丽娜. 车载视觉系统中障碍物检测与识别方法研究[D]. 南京: 南京航空航天大学, 2016.
- [4] Fan X H, Xu G L, Li W L, et al. Target segmentation method for three-dimensional LiDAR point cloud based on depth image[J]. Chinese Journal of Lasers, 2019, 46(7): 0710002.
- [5] 范小辉, 许国良, 李万林, 等. 基于深度图的三维激光雷达点云目标分割方法[J]. 中国激光, 2019, 46(7): 0710002.
- [5] Cao G P, Liu X S, Liu N, et al. Segmentation of subway tunnel wall surface objects based on laser 3D point cloud[J]. Acta Optica Sinica, 2020, 40(21): 2110001.
- [6] 曹桂萍, 刘行思, 刘念, 等. 基于激光三维点云分割地铁隧道壁表面物体[J]. 光学学报, 2020, 40(21): 210001.
- [6] Birant D, Kut A. ST-DBSCAN: an algorithm for clustering spatial-temporal data[J]. Data & Knowledge Engineering, 2007, 60(1): 208-221.
- [7] Wang W M, Sakurada K, Kawaguchi N. Incremental and enhanced scanline-based segmentation method for surface reconstruction of sparse LiDAR data [J]. Remote Sensing, 2016, 8(11): 967.
- [8] Huang G, Wu C Z, Lü N C. A study of laser radar object detection based on improved DBSCAN algorithm[J]. Journal of Transport Information and Safety, 2015, 33(3): 23-28.
- [9] 黄钢, 吴超仲, 吕能超. 基于改进 DBSCAN 算法的激光雷达目标物检测方法[J]. 交通信息与安全, 2015, 33(3): 23-28.
- [9] Zhao K, Xu Y C, Li Y L, et al. Large-scale scattered point-cloud denoising based on VG-DBSCAN algorithm [J]. Acta Optica Sinica, 2018,

- 38(10): 1028001.
- 赵凯, 徐友春, 李永乐, 等. 基于 VG-DBSCAN 算法的大场景散乱点云去噪 [J]. 光学学报, 2018, 38(10): 1028001.
- [10] Li Y Z. Research on SLAM of indoor robot based on LIDAR[D]. Guangzhou: South China University of Technology, 2016.
- 李昀泽. 基于激光雷达的室内机器人 SLAM 研究 [D]. 广州: 华南理工大学, 2016.
- [11] Hang Y J, Liu J Y, Li R B, et al. MEMS IMU/LADAR integrated navigation method based on mixed feature match[J]. Acta Aeronautica et Astronautica Sinica, 2014, 35(9): 2583-2592.
- 杭义军, 刘建业, 李荣冰, 等. 基于混合特征匹配的微惯性/激光雷达组合导航方法 [J]. 航空学报, 2014, 35(9): 2583-2592.
- [12] Lü Y Z, Sun Q, Bi G L. Recognition and repairing of surface hole in three dimensional laser scanning system[J]. Chinese Optics, 2016, 9(1): 114-121.
- 吕源治, 孙强, 毕国玲. 三维激光扫描系统中曲面空洞的识别与修复[J]. 中国光学, 2016, 9(1): 114-121.
- [13] Qiao J N. The environmental perception of unmanned platform based on the 2D laser radar [D]. Beijing: Beijing Institute of Technology, 2016.
- 乔佳楠. 基于二维激光雷达的无人运动平台环境感知方法研究 [D]. 北京: 北京理工大学, 2016.
- [14] Chavez-Garcia R O, Burlet J, Vu T D, et al. Frontal object perception using radar and mono-vision[C] // 2012 IEEE Intelligent Vehicles Symposium, June 3-7, 2012, Madrid, Spain. New York: IEEE Press, 2012: 159-164.
- [15] Li L J. Research on technology of road information extraction based on four-layer laser radar [D]. Beijing: Beijing University of Technology, 2016.
- 李龙杰. 基于四线激光雷达的道路信息提取技术研究 [D]. 北京: 北京工业大学, 2016.

## Adaptive Threshold Clustering Segmentation Method Based on Two-Dimensional Lidar

Wang Zhu<sup>1,2</sup>, Wang Zhi<sup>1,2\*</sup>, Zhang Xu<sup>1,2</sup>, Cui Can<sup>1,2</sup>, Wang Jian<sup>1,2</sup>

<sup>1</sup> School of Science, Beijing Jiaotong University, Beijing 100044, China;

<sup>2</sup> Key Laboratory of Luminescence and Optical Information Technology of Ministry of Education, Beijing Jiaotong University, Beijing 100044, China

### Abstract

**Objective** With the continuous advancement of science and technology, research into driverless smart cars has increased significantly. To realize environmental perception, driverless smart cars rely on sensors installed in the platform to collect and process surrounding environmental information. Sensors that perceive the external environment primarily include light detection and ranging (lidar), millimeter-wave radar, ultrasound, and cameras. Lidar is widely used in smart car obstacle detection and mapping navigation systems due to its high accuracy, large detection range, anti-interference properties, and the degree of depth information. Currently, two-dimensional lidar is widely used for obstacle detection. Obstacle clustering segmentation is a key technology in environment perception. Due to the complex environment characteristics and uneven distribution of data density, traditional clustering algorithms cannot achieve good clustering of different types of obstacles at different distances simultaneously, and obstacles can be missed and misdetected. Therefore, considering indoor obstacle detection requirements, the characteristics of lidar data and the geometric characteristics of indoor environments are analyzed and an improved adaptive threshold algorithm based on distance and obstacle characteristics is proposed. With the proposed algorithm, the threshold value is adjusted to change with the target distance and intra-class density. This method can effectively improve the correct detection rate of obstacles, and the segmentation accuracy reaches 92.23%.

**Methods** The proposed algorithm introduces the cluster density concept of the DBSCAN algorithm and an improved linear threshold algorithm. First, after receiving lidar data, the upper computer preprocesses the data, eliminates unstable points outside the effective range, and converts the remaining points to a rectangular coordinate system. Then, distance and density thresholds are set. The distance threshold changes adaptively with the distance of the received lidar data. The density threshold is the density average of the current class plus a multiple of its density

standard deviation, which can vary as the obstacle class inner density changes adaptively. Then, the starting point is classified as category 1. From the second point to the last point, it is determined whether the distance between the current point and the previous point is greater than the current distance threshold. If the distance is less than the threshold, it is classified into the current category. Otherwise, a new class is created, and it is classified into the new class. It is also determined whether the last point and the starting point are less than the threshold. If less, the last category will be classified into the first category, otherwise it will not be included.

**Results and Discussions** The indoor test results are shown in Fig. 6. As shown in Fig. 6(b), it is difficult for the linear threshold algorithm to consider the sparse scanning points of distant obstacles and obstacles closely distributed at a short distance. It can be seen from Fig. 6(c) that the improved DBSCAN algorithm will group different obstacles that are close together into one category. In Fig. 6(d), in the vicinity of the same coordinates, the proposed adaptive threshold algorithm based on distance and obstacle characteristics can distinguish smaller object distances at the same distance and can successfully segment objects with different distance data densities. The outdoor test results are shown in Fig. 8. Under complex outdoor conditions, the proposed, DBSCAN, and linear threshold algorithms successfully segmented and detected various obstacles at close distances. However, the linear threshold method incorrectly classified walls as noise, and the improved DBSCAN algorithm mistakenly detected walls as two separate classes. For metal aluminum plates, the linear threshold algorithm and the improved DBSCAN algorithm mistakenly detected several types of obstacles. The proposed adaptive threshold algorithm successfully segmented and detected all types of obstacles that are close to each other and did not cause over-segmentation of walls and aluminum plates at a distance. In addition, the positive detection rate is significantly improved.

**Conclusions** The experimental results showed that the improved clustering segmentation algorithm had the following advantages. First, it improved the positive detection rate of obstacle clustering and segmentation. Compared with the linear threshold algorithm, it had stronger environmental adaptability and could adapt to longer environmental distances and smaller object intervals. Second, compared with the global search of the DBSCAN algorithm, run time is reduced and the efficiency of obstacle detection and segmentation is improved.

**Key words** remote sensing; lidar; obstacle detection; clustering segmentation; density-based spatial clustering of applications with noise; linear threshold method

**OCIS codes** 280.3640; 280.5600; 280.3420