

DOI: 10.13973/j.cnki.robot.2017.0638

## 基于多激光雷达与组合特征的非结构化环境负障碍物检测

刘家银, 唐振民, 王安东, 石朝侠

(南京理工大学智能机器人研究所, 江苏 南京 210094)

**摘要:** 针对非结构化环境下自主式地面车辆 (ALV) 的负障碍物检测问题, 提出一种基于多激光雷达与组合特征的方法. 首先, 设计了一种具有互补能力的多激光雷达安装方式. 其次, 提出了基于幅向局部凸性和后沿壁局部密集特征的 64 线雷达负障碍物特征点对检测方法, 以及基于径向距离跳变和后沿壁局部密集特征的 32 线雷达负障碍物特征点对检测方法. 进而从负障碍物的时空融合角度, 采用贝叶斯法则对多传感器多帧特征点进行融合, 然后采用 DBSCAN (density-based spatial clustering of applications with noise) 对融合后的特征点进行聚类与过滤. 最后对数据进行栅格化, 提取负障碍物栅格. 实验结果表明, 本方法在非结构化复杂地形环境下具有良好的负障碍物检测性能.

**关键词:** 负障碍; 激光雷达; 非结构化环境; 自主式地面车辆

**中图分类号:** TP242.6

**文献标识码:** A

**文章编号:** 1002-0446(2017)-05-0638-14

## Negative Obstacle Detection in Unstructured Environment Based on Multiple LiDARs and Compositional Features

LIU Jiayin, TANG Zhenmin, WANG Andong, SHI Chaoxia

(Institute of Intelligent Robotics, Nanjing University of Science and Engineering, Nanjing 210094, China)

**Abstract:** For negative obstacle detection of autonomous land vehicle (ALV) in unstructured environment, a method based on multiple LiDARs and compositional features is proposed. Firstly, a multi-LiDAR installation manner with complementary ability is proposed. Secondly, two methods are presented: a negative obstacle feature point pair detection method with 64-beam LiDAR based on local convexity in amplitude direction and local dense features at up-side of a ditch, and a negative obstacle feature point pair detection method with 32-beam LiDAR based on range jump in radial direction and local dense features at up-side of a ditch. From the view of spatial and temporal fusion of the negative obstacle, a Bayesian rule is adopted to fuse the feature point pairs from multiple sensors and multiple frames. Then the DBSCAN (density-based spatial clustering of applications with noise) algorithm is applied to clustering and filtering the feature point pairs after fusion. Finally, the data are discretized to extract negative obstacle grid. The experimental results show that the proposed method obtains a good performance for detecting negative obstacles in unstructured environment.

**Keywords:** negative obstacle; LiDAR; unstructured environment; ALV (autonomous land vehicle)

### 1 引言 (Introduction)

环境感知技术是 ALV 在室外环境中实现自主导航的关键技术. 非结构化环境<sup>[1]</sup>中存在着陷坑、壕沟等低于地面且严重影响 ALV 安全行驶的负障碍物. 因此准确可靠的负障碍物检测成为在非结构化环境下 ALV 环境感知技术的重要组成部分.

Matthies 等人<sup>[2]</sup>提出基于热红外图像的负障碍物检测方法. 该方法基于夜间环境下负障碍物比凸障碍物和平坦地面散热少而温度更高的现象, 对红

外图像进行局部强度分析, 将显著的强度区域标记为潜在的负障碍物区域. 然后通过多帧验证与融合进行最终的负障碍物确认. Hu<sup>[3]</sup>等人提出基于视频序列的负障碍物检测方法. 他们的算法基于“负障碍物比周围环境要‘暗’且距离越远暗得越显著”的现象, 先在较远距离处根据亮度信息对潜在负障碍物进行检测与跟踪, 再在近距离处通过立体视觉的距离数据得出负障碍物的位置. 这 2 种典型的基于红外或视觉传感器的负障碍物检测方法对温度或光照等条件有一定要求, 具有一定的局限性, 且障

碍物检测鲁棒性不足: 基于热红外图像的方法<sup>[2,4]</sup>最大的局限性在于只能在夜间进行负障碍物检测且受天气环境影响比较大, 同时存在将动物等生命体误检为负障碍物的现象; 而基于图像序列的方法存在将地面的草木阴影误报为负障碍物的现象. 与红外和视觉传感器相比, 激光雷达具有直接、精确获得物体的距离信息且不受光照、天气等条件影响的优势, 因而广泛应用于 ALV 环境感知技术中<sup>[5-8]</sup>.

一般地, 基于激光雷达的负障碍物检测存在以下难点: 1) 可测深度有限, 即随着到激光雷达传感器距离的增加, 一定宽度的负障碍物能够观测到的有效深度值迅速降低; 2) 地面难以确定, 由于地表起伏不定, 非结构化环境下又没有标准的道路, 所以很难像城市环境一样拟合或者分割出较好的“路面”, 也就难以通过地面来推测负障碍物.

Schafer 等人<sup>[9]</sup>提出基于单线激光雷达扫描点的几何特征来检测负障碍物的方法. 宁火明<sup>[10]</sup>提出根据障碍物点在世界坐标系下的高度值来识别负高度障碍物的方法. 张博等人<sup>[11]</sup>通过判别能否提取数据缺失区域的外轮廓来识别负障碍物. Heckman 等人<sup>[12]</sup>提出基于遮挡标记的负障碍物检测方法, 通过 3 维体素沿着激光雷达扫描方向的滑动来寻找“无观察值”到“密集观察值”再到“正常观察值”的模式来定位负障碍物. Larson 等人<sup>[13]</sup>提出了负障碍物检测子 NODR (negative obstacle detector), 主要根据激光雷达扫描方向数据“缺口”张成的角度大于一定的阈值来估计潜在在负障碍物的位置, 然后利用 SVM (支持向量机) 分类器来检测负障碍物. Morton 等人<sup>[14]</sup>提出基于 HLD (height-length-density) 特征的凸负障碍物分类器, 他们通过对不可见栅格的信息进行栅格间信息传递, 求得不可见栅格的 HLD 三元组, 然后通过预训练的 3 维表得到 HLD 三元组的概率值并进行分类. Sinha 等人<sup>[15]</sup>先基于图像形态学方法来聚类潜在的负障碍物, 然后采用主成分分析方法提取特征, 判断可通行性. 商尔科等人<sup>[16]</sup>使用 32 线激光雷达, 提出基于 FFA (feature fusion based algorithm) 和 AMFA (adaptive matching filter based algorithm) 的负障碍物检测方法.

为了实现非结构化环境复杂地形下鲁棒的负障碍物检测, 本方法从以下 3 个角度来提高检测性能: 1) 从传感器安装角度, 提出一种互补式的多传感器安装方式. 这种安装方式可以有效提高单位面积

一定程度上解决观测数据的径向和幅向稀疏性, 提高负障碍物的观测概率. 2) 从负障碍物检测的角度, 提出一种基于组合特征的负障碍物检测方法, 即基于单线幅向局部凸性和后沿壁局部密集特征的 64 线激光雷达负障碍物特征点对检测方法, 以及基于单线径向距离跳变和后沿壁局部密集特征的 32 线激光雷达负障碍物特征点对检测方法. 3) 从负障碍物的时空融合角度, 采用贝叶斯法则对多传感器多帧观测值进行融合, 从而有效去除虚警, 提高检测结果的稳定性与鲁棒性. 本方法已成功应用于自主式地面车辆系统中, 实验证明本文方法在非结构化复杂地形环境下具有优良的负障碍物检测性能.

## 2 激光雷达检测负障碍物原理 (The principle of negative obstacle detection based on LiDAR)

本文介绍的负障碍物检测方法是在自主式地面车辆“行健 II 号”上进行开发与测试的, 如图 1 所示. 为检测负障碍物, ALV 上装备了 1 个 64 线激光雷达和 2 个 32 线激光雷达来获得周围环境的感知数据, 此外, ALV 还能从 GPS/INS (全球定位系统/惯性导航系统) 组合系统中获取车辆的实时姿态信息.



图 1 “行健 II 号”实验平台

Fig.1 “Xing Jian II” experimental platform

### 2.1 激光雷达配置

#### 2.1.1 激光雷达参数介绍

本方法使用美国 Velodyne 公司生产的 HDL-64ES2 64 线激光雷达和 HDL-32E 32 线激光雷达来获取感知数据. 下面先对 2 种激光雷达进行简单介绍. HDL-64ES2 激光雷达共有 64 线激光扫描束, 水平方向可视范围 (FOV) 为  $360^\circ$ , 水平角分辨率为  $0.09^\circ$ , 垂直方向 FOV 为  $26.8^\circ (+2^\circ \sim -24.8^\circ)$ , 垂直角分辨率大约为  $0.4^\circ$ . HDL-32E 激光雷达共有 32 线激光扫描束, 水平方向 FOV 为  $360^\circ$ , 水平角分辨率为  $0.16^\circ$ , 垂直方向 FOV 为  $41.34^\circ (+10.67^\circ \sim -30.67^\circ)$ , 垂直角分辨率大约为  $1.33^\circ$ .

### 2.1.2 激光雷达扫描模型

首先, 分析理想情况下激光雷达在大地平面上的扫描模型, 图2为扫描模型示意图。




图2 激光雷达扫描模型  
Fig.2 The LiDAR scan model

图2中,  $O_G-X_GY_GZ_G$  为大地坐标系,  $O_L$  为雷达坐标系原点且位于大地坐标系  $Z_G$  轴上. 点  $M$ 、 $N$ 、 $Q$  分别为第  $i$ 、 $j$ 、 $k$  条激光扫描线与大地平面的交点, 其到激光雷达的距离分别为  $r_i$ 、 $r_j$ 、 $r_k$ , 第  $j$ 、 $k$  条激光扫描线径向发射角 (与  $Z_G$  负方向的夹角) 均为  $\beta$ , 第  $i$  条与第  $j$  条激光扫描线径向发射角之差为  $\Delta\beta$ , 第  $i$ 、 $j$  条激光扫描线幅向发射角 (与  $X_G$  正方向的夹角) 均为  $\alpha$ , 第  $j$  条与第  $k$  条激光扫描线幅向发射角之差为  $\Delta\alpha$ , 激光雷达到地面的高度为  $h$ . 从图2中可以发现, 激光扫描线与大地平面的交点到激光雷达的距离满足关系式:

$$r_j = h / \cos \beta \quad (1)$$

其在  $XY$  轴平面的投影为

$$d_j = h \tan \beta \quad (2)$$

具有相同幅向发射角的相邻2条激光扫描线, 如图2第  $i$ 、 $j$  条激光扫描线, 其与地面交点的距离  $MN$  决定激光雷达的径向分辨率:

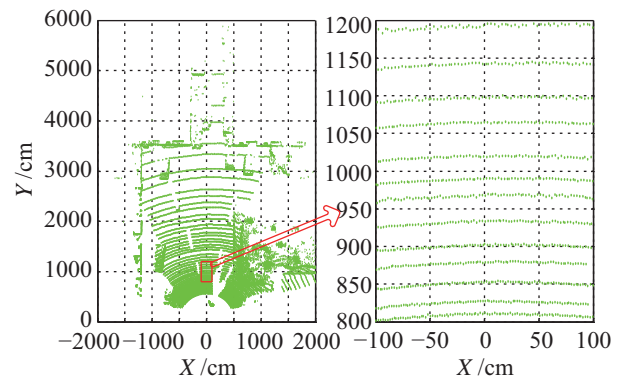
$$\Delta d_v = d_j - d_i = h(\tan \beta - \tan(\beta - \Delta\beta)) \quad (3)$$

对于具有相同径向发射角的2条激光扫描线, 如图2中第  $j$ 、 $k$  条激光扫描线, 由式(1)和(2)可知, 其与大地平面的交点到激光雷达的距离相同  $r_j = r_k$ ,  $j \neq k$ , 其在  $XY$  轴平面的投影也相同  $d_j = d_k$ ,  $j \neq k$ . 具有相同径向发射角的相邻2条激光扫描线在  $XY$  轴平面的投影形成一个等腰三角形, 底边  $NQ$  决定激光雷达的幅向分辨率:

$$\Delta d_H = 2d_j \sin \Delta\alpha / 2 = 2h \tan \beta \sin \Delta\alpha / 2 \quad (4)$$

### 2.1.3 激光雷达配置分析

常规的雷达安装方式为向上安装, 如图1中64线激光雷达. 该安装方式的特点是幅向分辨率高而径向分辨率较低, 扫描到的点云数据具有幅向密集性和径向稀疏性. 64线激光雷达在该安装方式下其径向角分辨率  $\Delta\beta \approx 0.4^\circ$ , 径向发射角相邻的激光扫描束在水平地面扫描半径差可根据式(3)得出. 由于  $\Delta\beta$  固定且近似不变, 径向发射角  $\beta$  越大, 扫描半径差  $\Delta d_v$  变化越大 (如图3(a)所示). 在安装高度为220 cm的情况下, 10 m处前后2条激光扫描束的扫描半径差值接近50 cm (如图3(b)所示), 导致50 cm宽的负障碍可能因正好处在2条扫描线之间而无法观测到, 但是这种宽度的负障碍影响ALV行驶的安全性. Schafer等人<sup>[9]</sup>采用对原始点云进行多帧累积的方法来降低数据的径向稀疏性. 但在越野环境下, 地形起伏多变, 很难精确地获得车辆的位姿信息, 导致点云级多帧累积误差较大. 而且在原始点云数据级 (百万级) 进行多帧配准融合, 时间开销往往过大, 使得系统实时性难以保证. 因此, 常规安装方式下的单一激光雷达由于其感知数据的局限性, 很难用于检测中远距离的负障碍物.



(a) 激光雷达XY平面点云图 (b) 局部区域放大图

图3 顶装激光雷达扫描结果径向稀疏性  
Fig.3 Radial sparseness of the measurements of upward setup LiDAR

在激光雷达安装高度固定的条件下, 由式(1)可知扫描距离  $r_j$  与径向发射角  $\beta$  正相关. 即, 如果径向发射角确定, 扫描距离也就确定. 因此, 提高径向分辨率只能通过提高径向角分辨率来实现. 从激光雷达的参数信息可以发现, 其垂直角分辨率远远大于水平角分辨率. 若将激光雷达侧向安装 (如图1中向左侧和向右侧安装的2个32线激光雷达), 即将激光雷达的水平角分辨率转变为大地坐标系下的径向角分辨率, 将提高扫描结果的径向分辨率. 但64线激光雷达体积与质量不太适合水平侧装,



因此, 我们选择与其性能近似, 但质量与体积更合适的 32 线激光雷达进行侧装. 这样, 就可以将  $\Delta\beta$  的值由  $0.4^\circ$  降低到  $0.16^\circ$ , 减小相邻激光扫描线的径向距离, 提高径向分辨率.

侧装的安装方式虽然提高了径向分辨率, 但其幅向角分辨率由顶装 64 线激光雷达的  $0.09^\circ$  变为侧装 32 线激光雷达的约  $1.33^\circ$ , 由式 (4) 可知, 幅向分布率降低了大约 13.5 倍. 如图 4(b) 蓝色扫描点所示, 其在 16 m 左右相邻激光扫描线的幅向距离大约为 50 cm. 因此, 可以得出侧装的 32 线激光雷达幅向分辨率较低, 具有幅向稀疏性.

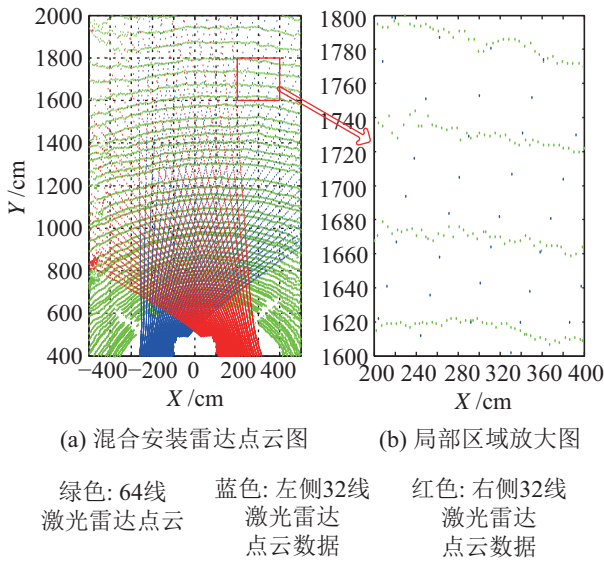


图 4 混合安装方式激光雷达扫描结果图

Fig.4 Measurements from hybrid setup LiDARs

为解决向上安装方式导致的径向稀疏性和侧向安装方式导致的幅向稀疏性问题, 本文提出一种激光雷达的混合安装方式. 具体地, 向上安装一个 64 线激光雷达和左右 2 个侧向各安装一个 32 线激光雷达, 其扫描结果如图 4 所示. 该安装方式具有以下优点: 1) 提高单位面积的点云密度, 减少点云数据缺失区域 (如图 4(a) 所示), 提高检测准确度; 2) 一定程度上解决观测数据的径向和幅向稀疏性, 提高负障碍物的观测概率; 3) 2 种不同安装方式的激光雷达, 其点云数据具有不同的负障碍特征, 可提高检测结果的鲁棒性.

## 2.2 基于激光雷达的负障碍物检测原理

### 2.2.1 激光雷达负障碍物检测的难点

衡量负障碍物可检性的一个重要指标是其在传感器视野中张成角度的大小. 图 5 为激光雷达负障碍物检测的几何模型图, 当宽度为  $w$  的负障碍物与激光雷达水平距离为  $d$  时, 可得到  $\tan\beta = d/h$  和  $\tan(\beta + \theta) = (d+w)/h$ , 进而可以得到:

$$\begin{aligned} \tan\theta &= \tan(\beta + \theta - \beta) \\ &= \frac{\tan(\beta + \theta) - \tan\beta}{1 + \tan(\beta + \theta)\tan\beta} = \frac{hw}{h^2 + r(r+w)} \end{aligned} \quad (5)$$

当  $r \gg h$  时,  $\tan\theta$  的值很小, 张成角  $\theta$  近似为

$$\theta = hw/[r(r+w)] \quad (6)$$

由式 (6) 可知, 张成角  $\theta$  与距离  $r$  的平方成反比. 可见随着负障碍物离传感器距离越来越远, 其在传感器视野中张成角度以距离的平方倍减小, 负障碍物可检性越来越小.

负障碍物可检性的另外一个重要参数是可见高差, 由图 5 可知, 其在传感器视野中可见高差  $\Delta h$  可以由相似三角形知识推出:

$$\Delta h = \frac{hw}{d} = \frac{hw}{h \tan\beta} = w \cot\beta \quad (7)$$

由式 (7) 可知, 可见高差与雷达高度以及负障碍物自身宽度成正比, 与负障碍物到激光雷达距离成反比. 当雷达高度为 220 cm 时, 假设 8 m 处有宽度为 60 cm 的负障碍物, 则单激光扫描线能检测到的高度差 (有效高差) 为  $\Delta h \approx 16.5$  cm. 随着距离增大, 激光雷达能检测的有效高差变小. 考虑到越野环境下地表复杂多样, 地形起伏很容易超过 20 cm, 而车体自身俯仰和偏航等多种姿态也会造成高差计算错误, 以致于只通过高差难以与地面正常起伏进行区分, 我们将这种情况称为“可测高差有限性”. 在非结构化环境下, 由于可测高差的有限性, 基于几何高差检测负障碍物的方法不再奏效.




图 5 负障碍物的几何模型


Fig.5 The geometric model of negative obstacle

### 2.2.2 幅向局部凸性


根据本方法 64 线激光雷达的安装方式, 该雷达的激光扫描束在大地平面上按照幅向圆周扫描, 具有幅向密集性. 对于单个激光扫描束来说, 其径向发射角  $\beta$  固定不变, 因此可以将单激光扫描束返回的距离值  $r$  看作幅向发射角  $\alpha$  的函数  $r = f(\alpha)$ , 其在水平地面的理想扫描结果为圆形或者椭圆形, 相邻扫描点距离返回值差异很小. 从图 5 可以发现, 相对于水平地面, 激光束扫描到负障碍物时其距离返回值会有显著增加. 最大的增加值为

$$\Delta r = \sqrt{w^2 + \Delta h^2} = w\sqrt{1 + \cot^2\beta} \quad (8)$$

因此当扫描到负障碍物时, 就会在  $r-\alpha$  图上呈现出一段具有一定宽度的高值, 形成一个凸起, 如图 6 所示. 这样, 就可以通过检测  $r-\alpha$  图中的“上升沿—高值—下降沿”, 获得潜在的负障碍特征点, 即将负障碍特征点检测问题转化为 1 维信号问题. 对比式 (7) 和 (8), 当径向发射角  $\beta$  较大时, 可以发现  $\Delta r \gg \Delta h$ . 因此相对于可见高差特征,  $r-\alpha$  图中的凸起具有更好的可检测性.



(a) 64线激光雷达点云图



(b) 图(a)中红色扫描线的  $r-\alpha$  图

图6 幅向局部凸性


Fig.6 Local convexity in amplitude direction

### 2.2.3 径向距离跳变


根据本方法 32 线激光雷达的安装方式, 该雷达的激光扫描束在大地平面上按径向由近及远扫描. 对于单个激光扫描束来说, 其幅向发射角  $\alpha$  为固定值, 因此可以将单激光扫描束返回的距离值  $r$  看作径向发射角  $\beta$  的函数  $r = f(\beta)$ . 图 7(b) 为 32 线激光雷达一条激光扫描束在大地平面上返回的距离值  $r$  随径向发射角  $\beta$  变化的情况.

从图 7 可以发现, 激光雷达扫描到负障碍物

时, 返回的距离值会发生跳变, 如图 7(b) 红色圆圈所示. 根据式 (8), 负障碍宽度越宽, 距离返回值跳变越明显 (即负障碍区域越显著).



(a) 32线激光雷达点云图



(b) 图(a)中红色扫描线的  $r-\beta$  图

图7 径向距离跳变

Fig.7 Range jump in radial direction

### 2.2.4 后沿壁数据局部密集

当激光雷达扫描到负障碍物时, 返回的距离值会增大, 导致本应该扫描到负障碍物后壁前方的扫描线都集中到负障碍物的后壁, 造成负障碍物后壁处相邻雷达扫描线间距离较小, 点密度比较大, 形成一个“密集带”的现象. 本文将这种现象称为后沿壁数据局部密集特征. 图 7(a) 为侧装 32 线激光雷达扫描到前方陷坑时的俯视图, 负障碍后壁处扫描点密度明显大于水平地面处的扫描点密度 (图 7(a) 红色椭圆处所示). 在图 6(a) 的红色椭圆处可以发现相同的现象.

### 2.2.5 局部区域数据显著缺失

在负障碍处, 由于本应扫描到负障碍物后壁前方的扫描线扫描到了负障碍物的后壁, 因此会出现

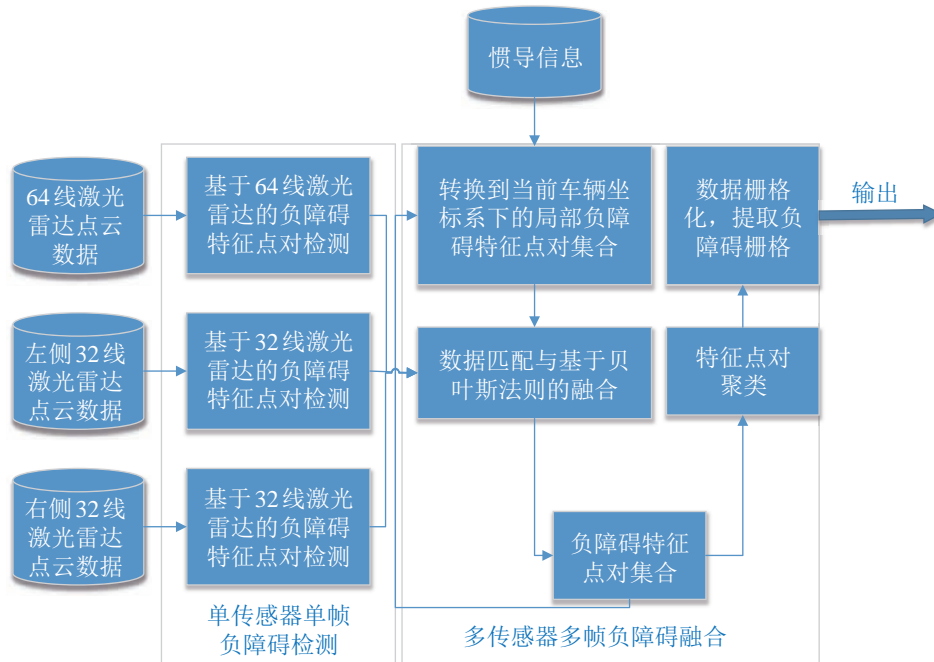


图 8 负障碍物检测流程图

Fig.8 Flow chart of negative obstacles detection

负障碍区域无扫描点存在的现象. 本文将这种现象称为“局部区域数据显著缺失”. 从视觉上看, 若将雷达点云数据投影到  $XY$  轴形成的 2 维平面, 会发现负障碍处有明显的空缺, 因而看上去像一个较大的“黑块”. 如图 6(a) 和图 7(a) 红色椭圆区域所示, 负障碍物区域的数据缺失视觉效果比较显著.

### 3 基于多激光雷达与组合特征的负障碍物检测 (Negative obstacle detection based on multiple LiDARs and compositional features)

基于多激光雷达与组合特征的负障碍物检测主要包括基于单传感器组合特征的潜在负障碍物特征点检测和多传感器多帧负障碍物特征融合两步. 第 1 步: 根据第 2 节描述的负障碍物特征, 对每个激光传感器基于组合特征提取潜在负障碍物特征点对; 第 2 步: 将潜在负障碍物特征点对的历史结果转换到当前坐标系, 运用贝叶斯法则将其与第 1 步求得的负障碍物特征点对进行融合, 然后进行特征点对聚类, 数据栅格化, 获得负障碍物区域的检测结果. 检测流程如图 8 所示.

#### 3.1 基于单帧 64 线雷达的负障碍物特征点对检测

在本文所述 64 线激光雷达的安装方式下, 每个激光扫描束都采用幅向圆周扫描. 在负障碍处, 单个激光扫描束返回的点云数据呈现幅向局部

凸性, 多个激光扫描束的返回值呈现后沿壁局部密集以及局部数据显著缺失的现象. 基于这些现象, 本文提出基于组合特征的单帧 64 线激光雷达负障碍物特征点对检测算法.

首先, 定义 64 线激光雷达的点云描述子. 对任一扫描点  $P$ , 其点云描述子为  $(n_p, \theta_p, r_p, d_p, x_p, y_p, z_p)$ ,  $n_p$  为  $P$  对应的排序后的激光器序号 (激光器序号按俯仰角由大到小排列, 俯仰角最大的为 1 号, 次大的 2 号, 依次类推),  $\theta_p$  为  $P$  在 64 线雷达坐标系下与  $X$  轴正方向的夹角 (逆时针为正),  $r_p$  为点  $P$  到激光雷达的距离值,  $d_p$  为  $P$  的密度特征,  $(x_p, y_p, z_p)$  为  $P$  在车体坐标系下的坐标.

基于单帧 64 线雷达点云的负障碍物特征点对检测算法流程如图 9 所示.




图 9 基于 64 线激光雷达的负障碍物特征点对检测流程图  
Fig.9 Detection flow chart of feature point pairs of a negative obstacle based on HDL 64 LiDAR

具体步骤为:

1) 坐标转换

对任意一个原始扫描点  $P$ , 利用文 [7] 中的方

法将其从极坐标系转化到雷达 3 维坐标系, 得到雷达坐标系下的 3 维坐标  $\mathbf{P}_L = (x'_p, y'_p, z'_p)$ , 依此计算幅向偏转角  $\theta_p$ , 然后将  $\mathbf{P}_L$  转换到车辆坐标系下  $\mathbf{P}_V = (x_p, y_p, z_p)$ , 获得点云描述子的  $(x_p, y_p, z_p)$  值.

$$\mathbf{P}_V = \mathbf{R} \times \mathbf{P}_L + \mathbf{T} \quad (9)$$

其中,  $\mathbf{R}, \mathbf{T}$  为激光雷达的外参,  $\mathbf{R}$  为  $3 \times 3$  的旋转矩阵,  $\mathbf{T}$  为  $3 \times 1$  的平移向量.

### 2) 最大值滤波

对每个激光扫描束返回的原始点云数据的距离值作半径为 3 的最大值滤波, 以突出负障碍物的几何特征. 点云描述子的  $r_p$  为滤波后的距离值.

### 3) 点密度估计

统计该点  $T_{d64}$  范围内存在扫描点的激光器数目, 即点云描述子中密度  $d_p$ , 其中

$$T_{d64} = 0.55 \times \max(\Delta r_{n_p}, \Delta r_{n_p+1}) \quad (10)$$

其中,  $\Delta r_{n_p}$  为第  $n_p$  个激光器与第  $n_p - 1$  个激光器的扫描半径差.

### 4) 提取负障碍特征点

对每一个激光扫描束返回的点云数据, 提取潜在的负障碍特征点. 具体步骤如表 1 所示.

表 1 基于 64 线雷达检测负障碍特征点的伪代码

Tab.1 Pseudo-code for detecting negative obstacle points based on HDL 64 LiDAR

1.	roi_points = ExtractROIPoints();
2.	for $i^{\text{th}}$ roi_points
3.	diff = DistDifferencenNeighborPoint( $i$ );
4.	if diff > $T^+$ then label[ $i$ ] = RISE_EDGE;
5.	else if diff < $T^-$ then label[ $i$ ] = FALL_EDGE;
6.	end for
7.	convex_paris = FindConvexPair(label);
8.	for $m^{\text{th}}$ convex_paris
9.	convex_points = GetConvexPoints( $m$ );
10.	mean_dist = MeanDist(convex_points);
11.	mean_density = MeanDensity(convex_points);
12.	if mean_dist > left_mean_dist && mean_dist > right_mean_dist && mean_density > $D_{th64}$
13.	then nod_point_array.push(convex_points);
14.	end for

首先对于单激光扫描束的扫描数据, 提取感兴趣区域的点云描述子. 对感兴趣区域中的每一个扫描点, 计算其与 5 邻域范围内扫描点的距离差值

(取绝对值大者). 若差值大于正阈值  $T^+$ , 则标记为上升沿; 若差值小于负阈值  $T^-$ , 则标记为下降沿. 然后提取上升沿和下降沿对. 计算上升沿和下降沿之间点的距离均值和密度均值. 若距离均值高于上升沿之前和下降沿之后一定范围内扫描点的距离均值且密度均值大于阈值  $D_{th64}$ , 说明存在后沿壁数据局部密集的凸起, 将凸起部分的点标记为潜在的负障碍特征点. 实验中距离差值  $T^+$  和  $T^-$  分别设置为 20 cm 和 -20 cm, 密度阈值设置为 1.75.

### 5) 光线追踪的特征点对提取与分析

(1) 基于光线追踪的特征点对提取: 对第 4) 步提取的任意一个潜在负障碍特征点, 根据图 5 中负障碍物的几何模型, 假设该负障碍物点为  $B$ , 然后找到径向前后激光束, 且与其幅向发射角近似相同的扫描点. 具体步骤如表 2 所示.

表 2 特征点对匹配函数的伪代码

Tab.2 Pseudo-code of the FindMatchPoint function

1.	$m = n_A - 1$ ;
2.	while $m \neq 0$ do
3.	$A = \text{FindPoint}(m, \theta_A - \varepsilon, \theta_A + \varepsilon)$ ;
4.	if $A \neq \emptyset$ then break;
5.	else $m = m - 1$ ;
6.	end
7.	$m = n_A + 1$ ;
8.	while $m < 64$ do
9.	$C = \text{FindPoint}(m, \theta_A - \varepsilon, \theta_A + \varepsilon)$ ;
10.	if $C \neq \emptyset$ then break;
11.	else $m = m + 1$ ;
12.	end

即从  $n_A - 1$  激光器开始, 按照序号由大到小依次在  $(\theta_A - \varepsilon, \theta_A + \varepsilon)$  ( $\varepsilon = 0.09^\circ$  为常量) 范围内寻找是否存在扫描点, 直到找到为止, 假设找到的匹配扫描点为  $A$ . 同理, 从  $n_A + 1$  激光器开始按照序号由小到大寻找点  $C$ .

(2) 特征点对分析: 负障碍物为具有一定宽度的低于地面区域, 同时负障碍物处存在局部区域数据显著缺失的特征. 根据这一特征, 分析上面提取的特征点  $A, B$  之间的区域是否为负障碍. 具体方法如下:

a) 计算  $AB$  和  $BC$  之间平面距离以及  $BC$  的高差:

$$d_{AB} = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2} \quad (11)$$

$$d_{BC} = \sqrt{(x_B - x_C)^2 + (y_B - y_C)^2} \quad (12)$$

$$\Delta z_{BC} = z_C - z_B \quad (13)$$



b) 判断当前点对是否满足以下限制:

$$\begin{cases} d_{AB} \geq w_{\min} \\ d_{AB} \geq \gamma_1 d_{BC} \\ \Delta z_{BC} \geq \gamma_2 (hd_{AB}/y_A) \end{cases} \quad (14)$$

其中  $w_{\min}$  为最小负障碍宽度,  $\gamma_1, \gamma_2$  为常量. 若满足式 (14) 的 3 个条件, 则将  $AB$  添加到负障碍物特征点对集合中. 实验中最小负障碍物宽度设置为 30 cm, 常量  $\gamma_1, \gamma_2$  分别设置为 1.5 和 0.15.

图 10 为采用单帧 64 线激光雷达的负障碍特征点对检测结果示意图. 黄色点和紫色点为基于幅向局部凸性检测到的凸起点, 其中黄色点为不满足后沿壁密集条件的凸起点, 紫色点为满足后沿壁密集条件的凸起点. 可以发现, 基于幅向局部凸性和后沿壁密集特征能准确检测出负障碍物后沿壁特征点. 白色线段和蓝色线段分别为基于光线追踪提取的  $BA$  和  $BC$  连线, 且其满足式 (14) 的 3 个条件.




图 10 基于 64 线激光雷达的负障碍特征点对检测结果图  
Fig.10 Detection result of feature point pairs of a negative obstacle based on HDL 64 LiDAR

### 3.2 基于单帧 32 线雷达的负障碍物特征点对检测

相对于顶装的 64 线雷达, 侧装的 32 线雷达具有更高的径向分辨率, 更适合负障碍物检测. 对于 32 线雷达的任一扫测点, 假设为点  $P$ , 其点云描述子定义为  $(n_P, r_P, d_P, x_P, y_P, z_P)$ . 描述子中各成员含义与 64 线点云描述子中对应成员含义相同.

基于单帧 32 线雷达点云的负障碍检测算法流程如图 11 所示.

具体步骤为:

1) 坐标转换

根据激光雷达的内参和外参, 利用文 [8] 中方法将扫描点转化到激光雷达笛卡儿坐标下, 然后再利用式 (9) 将其转换到车辆 3 维坐标系下.






图 11 基于 32 线激光雷达的负障碍特征点对检测流程图  
Fig.11 Detection flow chart of feature point pairs of a negative obstacle based on HDL 32 LiDAR



(a) 32 线激光雷达点云图



(b) 图(a)中蓝色扫描线的  $r-\beta$  图

图 12 32 线激光雷达的缺失点补偿图

Fig.12 Missed measurement compensation for HDL 32 LiDAR

#### 2) 缺失点补偿

由于镜面反射、材料吸收等原因, 激光器发射出去的光线可能没有返回值, 进而产生径向距离跳变的现象. 为解决这一问题, 本文对 32 线雷达点云数据进行缺失点补偿操作. 为了提高计算效率, 用相邻激光器具有相同垂直发射角的扫描点来估



计缺失点. 用于缺失点补偿的扫描点满足扫描距离变化有序以减小补偿的缺失点的误差. 从物理学的角度来说, 缺失点的真实位置不能被准确复原, 只能估计其大体的扫描距离. 因此, 本文只采用补偿点来辅助判断径向距离跳变, 而不采用其作其他处理.

图 12 中红色点为补偿的消失点, 从图 12(b) 中可以发现, 补偿的消失点可以辅助排除因缺失点导致的径向距离跳变 (即补偿点后的黑色扫描点).

### 3) 点密度估计

对任一原始扫描点  $P$ , 计算其与同一扫描线上 (即  $n_p$  值相同) 扫描点的距离, 若其小于  $T_{d32}$ , 则将其点密度  $d_p$  加 1. 实验中  $T_{d32}$  设置为 15 cm.

### 4) 提取潜在的负障碍物特征点

对每一个激光扫描束返回的单线点云数据, 提取潜在的负障碍物特征点. 具体步骤如表 3 所示.

表 3 基于 32 线雷达检测负障碍物特征点的伪代码

Tab.3 Pseudo-code for detecting negative obstacle points based on HDL 32 LiDAR

1.	<b>for</b> $i^{\text{th}}$ point
2.	$r_{\text{diff}} = \text{DistChangeDifferencePrePoint}(i);$
3.	<b>if</b> $r_{\text{diff}} > T_{32}$ <b>then</b>
4.	<b>if</b> $d_i > D_{\text{th}32}$ <b>then</b> label[ $i$ ] = JUMP;
5.	<b>else</b> label[ $i$ ] = NORMAL;
6.	<b>else</b> label[ $i$ ] = NORMAL;
7.	<b>end for</b>

即对于单激光扫描束中的每个扫描点, 计算其距离变化 (即其与前一个扫描点的扫描距离差) 与前一个扫描点的距离变化的差值. 若距离差大于阈值  $T_{32}$ , 则认为该处存在径向距离跳变, 然后再判断该点的密度是否大于阈值  $D_{\text{th}32}$ . 若 2 个条件都满足, 则将该点标记为潜在的负障碍物特征点. 实验中  $T_{32}$ 、 $D_{\text{th}32}$  分别设置为 30 cm 和 4.

### 5) 光线追踪的特征点对提取与分析

(1) 基于光线分析的特征点对提取: 对第 4) 步提取的任意一个潜在负障碍物特征点, 根据图 5 中负障碍物的几何模型, 假设该负障碍物点为  $B$ , 然后提取同一激光扫描线的前一个扫描点, 假设其为  $A$ . 再提取同一激光扫描线的后一个扫描点, 假设其为  $C$ .

(2) 特征点对分析: 与基于单帧 64 线雷达的负障碍物特征点对检测方法第 5) 步中特征点对分析方法相同.

图 13 为采用单帧 32 线激光雷达的负障碍物特征

点对检测结果示意图. 蓝色点为满足径向距离跳变的扫描点, 白色点为同时满足径向距离跳变和后沿壁密集条件的凸起点. 可以发现, 基于径向距离跳变能检测出大部分潜在负障碍物特征点, 但是其误检特征点较多. 而后沿壁密集特征可以过滤掉基于径向距离跳变的误检特征点. 白色线段为基于光线追踪提取的  $BA$  连线, 且其满足式 (14) 的 3 个条件 ( $w_{\text{min}}$  设置为 30 cm, 常量  $\gamma_1, \gamma_2$  分别设置为 5 和 0.4). 可以发现, 利用式 (14) 能进一步过滤误检的负障碍物特征点, 如图 13 中白色方框内的 2 个白色点.




图 13 基于 32 线激光雷达的负障碍物特征点对检测结果图  
Fig.13 Detection result of feature point pairs of a negative obstacle based on HDL 32 LiDAR

### 3.3 多传感器多帧负障碍物融合

多传感器多帧负障碍物融合主要步骤如下:

#### 1) 数据对齐

利用惯导信息, 将全局坐标系下保存的局部历史特征点对转换到当前车辆坐标系下. 假设转换到当前车辆坐标系下的特征点对集合为  $G_h$ .

#### 2) 数据匹配与融合

假设当前 64 线雷达检测到的特征点对集合为  $G_{64}$ . 对于  $G_h$  中任一特征点对, 根据特征点对距离最近原则, 从  $G_{64}$  中找到特征点对. 若两者的距离小于阈值常量  $d_{\text{min}}$  (实验中设置为 10 cm), 则采用贝叶斯法则来对其进行融合操作:

$$\begin{aligned}
 & P(N|X_i, X_{i+1}) \\
 &= \frac{P(X_{i+1}|N)}{P(X_{i+1}|N)P(N|X_i) + P(X_{i+1}|\bar{N})P(\bar{N}|X_i)} P(N|X_i)
 \end{aligned} \quad (15)$$

其中,  $P(N|X_i)$  表示前  $i$  次观测得到的该特征点对存

在负障碍物的后验概率,  $P(X_{i+1}|N)$  表示第  $i+1$  次观测到该特征点对存在负障碍的先验概率。

对  $G_h$  中任一特征点对, 再分别在 2 个 32 线雷达检测到的特征点对集合中作相同处理。

若  $G_h$  中的某一特征点对在 3 个雷达的当前特征点对集合中都没能在  $d_{min}$  范围内找到特征点对, 则采用式 (16) 对其进行处理:

$$P(N|X_i, \bar{X}_{i+1}) = \frac{P(\bar{X}_{i+1}|N)}{P(\bar{X}_{i+1}|N)P(N|X_i) + P(\bar{X}_{i+1}|\bar{N})P(\bar{N}|X_i)} P(N|X_i) \quad (16)$$

若求得的概率值小于一个阈值常量, 则将其从  $G_h$  中删除。

对于 3 个雷达的当前特征点对集合中没能与  $G_h$  中任一特征点对匹配的特征点对, 利用式 (15) 计算其后验概率, 其中初始化后验概率  $P(N|X_0)$  为非零常量。然后将其添加到  $G_h$  中。

最后利用惯导信息, 将  $G_h$  投影到全局坐标系中, 更新全局坐标系下的历史负障碍物特征点对信息。

表 4 DBSCAN 函数的伪代码

Tab.4 Pseudo-code of the DBSCAN function

1.	CInd = 0;
2.	for each feature pair Fp in dataset $G'_h$
3.	if(IsVisited(Fp)==true) continue;
4.	mark Fp as visited;
5.	NeighborFPs = NeighborFPs(Fp, $T_{dbscan}$ );
6.	if(sizeof(NeighborFPs) < MinFPs)
7.	mark Fp as Noise;
8.	else
9.	add Fp to cluster CInd;
10.	ExpandCluster(Fp, NeighborFPs, CInd);
11.	CInd++;
12.	end for

### 3) 特征点对聚类

第 2) 步结果  $G_h$  中负障碍物特征点对不具备相关性, 同时还存在负障碍数目未知这一难点。DBSCAN<sup>[17]</sup> 算法是一种基于密度的空间距离算法。该算法具有不用预设类别数以及可以过滤噪声点的优点, 可以很好地对第 2) 步的负障碍物特征点对进行聚类关联, 进而获得负障碍物的数目及分布区域范围。因此, 本文采用 DBSCAN 算法来解决负障碍物特征点对的关联问题, 具体步骤如下: 首先,

根据  $G_h$  中特征点对存在负障碍的后验概率值对其进行过滤, 获得有效的特征点对集合  $G'_h$ ; 然后, 采用表 4 的 DBSCAN 算法对  $G'_h$  进行聚类。

表 5 ExpandCluster 函数的伪代码

Tab.5 Pseudo-code of the ExpandCluster function

1.	for each feature pair Fp' in NeighborFPs
2.	if(IsVisited(Fp')==false)
3.	mark Fp' as visted;
4.	NeighborFPs' = NeighborFPs(Fp', $T_{dbscan}$ );
5.	if(sizeof(NeighborFPs') >= MinFPs)
6.	Merge NeighborFPs with NeighborFPs';
7.	if Fp' is not yet member of any cluster;
8.	add Fp' to cluster CInd;
9.	end for

在进行 DBSCAN 聚类时, 任意 2 个特征点对的距离为其在激光线发射方向重合部分的距离均值。  $T_{dbscan}$  为邻域半径距离, MinFPs 为最小邻域点数。实验中分别设置为 40 cm 和 4。

最后对每一类负障碍特征点提取其外接轮廓, 轮廓范围内的区域即为负障碍区域。

图 14 为采用 DBSCAN 算法对  $G'_h$  进行聚类的结果示意图。其中蓝色特征点对表示第 1 个负障碍物类, 绿色特征点对表示第 2 个负障碍物类, 白色特征点对为噪声点。对于每一个障碍物类, 图 14 中采用红色折线段来描述聚类后负障碍物的外接轮廓。



图 14 DBSCAN 聚类结果

Fig.14 Clustering result by DBSCAN

### 4) 数据栅格化

以车辆惯导位置为坐标原点, 以车体正方向为 Y 轴, 将车辆所在的局部区域划分为 20 cm × 20 cm 的栅格图。若栅格与第 3) 步中获得的负障碍区域重合, 则将该栅格标记为负障碍栅格。

## 4 实验与分析 (Experiments and analysis)

### 4.1 实验数据和场景介绍

为了验证本文提出方法的性能,在非结构化环境中采集 6000 帧数据,每帧包含可见光数据、32 线激光雷达数据、64 线激光雷达数据和 GPS/INS 组合定位数据.由于非结构化场景比较复杂,选择有负障碍物的 3866 帧数据进行人工标记,共标记了 5350 个负障碍物目标.对每帧点云数据,在 32 线和 64 线激光雷达数据俯视图上对负障碍物进行标记,其中负障碍物尺寸主要有 100 cm × 50 cm、100 cm × 80 cm、150 cm × 60 cm 和 100 cm × 100 cm 等.场景中几种典型负障碍物场景如图 15 所示.



图 15 典型负障碍物场景

Fig.15 Typical scenes of negative obstacle

实验运行的环境为 Intel i7 4 核处理器,内存为 16G.为提高算法的运行效率,采用 C++ 来实现本文提出的算法.

### 4.2 定量分析

首先量化负障碍物目标的尺寸,然后针对不同尺寸、不同距离利用式 (17) 来统计召回率.

$$P_{\text{recall}} = \frac{T_p}{T_p + F_N} \quad (17)$$

其中  $T_p$  为正确检测到的负障碍数目,  $F_N$  为未检测到的负障碍数目.

关于如何描述负障碍物目标区域,有 2 种方案.方案 1 是对负障碍物区域标记点序列求最小包围椭

圆,使用椭圆的长轴和短轴来描述障碍尺寸;方案 2 是通过统计负障碍物区域内栅格数目来量化障碍尺寸.在具体应用中,选用方案 2,采用手工标记负障碍物区域栅格数目来量化障碍尺寸,其中栅格尺寸为 20 cm × 20 cm.

手工标记的负障碍物区域范围一般要比实际负障碍物区域范围大,所以标记的负障碍物区域栅格数目要比实际负障碍物栅格数目大.一般地,对于实际尺寸为  $l \times w$  的矩形负障碍物,其真实栅格数为  $n_{\text{real}} = (\lfloor l/c \rfloor + 1) \times (\lfloor w/c \rfloor + 1)$ .假设标记时,障碍长度会被扩大  $\Delta l$ ,障碍宽度被扩大  $\Delta w$ ,标记区域算出的栅格数  $n_{\text{mark}} = (\lfloor (l + \Delta l)/c \rfloor + 1) \times (\lfloor (w + \Delta w)/c \rfloor + 1)$ .取  $l = 100$  cm,  $w = 60$  cm,  $\Delta l = 30$  cm,  $\Delta w = 20$  cm,计算可得  $n_{\text{real}} = 24$ ,  $n_{\text{mark}} = 35$ .所以尺寸为 100 cm × 60 cm 的负障碍物对应的栅格数目大致在 24 ~ 35 之间.

对每个标记目标计算中心位置,使用标记区域中心到 ALV 惯导中心的距离来表示标记目标的距离.根据栅格数目进行分段统计,得到表 6 各种栅格数目的标记区域在不同距离段内的统计表.由于栅格数为 50 ~ 55 区间的标记区域过少,在这个区间统计召回率误差过大,因此将其与栅格数为 45 ~ 49 的区间合并统计.

根据标记区域中心位置和栅格数目,对标记区域被检测出来的次数进行分段统计,得到表 7 各种栅格数目的标记区域在不同距离段上的召回率统计表.

从表 7 可以发现:标记区域的栅格数目越大,其召回率相对越大;随着负障碍物距车体距离的增加,其召回率下降越来越快.10 m 以内,本文提出的方法能给出可靠的负障碍物检测结果.10 m ~ 16 m 之间,本文提出的方法能对较大的负障碍物给出较为可靠的负障碍物检测结果.本文提出的方法最远能够在 20 m 处检测到负障碍物.

表 6 各种栅格数目的标记区域在不同距离段的出现次数

Tab.6 The occurrence number of marked areas with different grid numbers at different distances

距离段栅格数	6 m ~ 8 m	8 m ~ 10 m	10 m ~ 12 m	12 m ~ 14 m	14 m ~ 16 m	16 m ~ 18 m	18 m ~ 20 m
15 ~ 19	86	92	89	88	68	46	45
20 ~ 24	92	189	167	155	110	95	93
25 ~ 29	101	192	187	157	123	81	75
30 ~ 34	85	184	174	163	154	89	84
35 ~ 39	94	196	157	140	131	91	83
40 ~ 44	89	184	84	80	65	53	56
45 ~ 55	83	123	89	85	71	68	64



表 7 各种栅格数目的标记区域在不同距离段的召回率

Tab.7 The recall rates of marked areas with different grid numbers at different distance

距离段栅格数	6 m ~ 8 m	8 m ~ 10 m	10 m ~ 12 m	12 m ~ 14 m	14 m ~ 16 m	16 m ~ 18 m	18 m ~ 20 m
15 ~ 19	0.977	0.891	0.787	0.693	0.426	0.217	0.044
20 ~ 24	0.957	0.862	0.79	0.781	0.482	0.326	0.118
25 ~ 29	0.96	0.922	0.85	0.72	0.512	0.284	0.173
30 ~ 34	0.941	0.929	0.839	0.773	0.571	0.326	0.167
35 ~ 39	0.957	0.918	0.892	0.8	0.618	0.429	0.205
40 ~ 44	0.955	0.951	0.905	0.775	0.646	0.415	0.179
45 ~ 55	0.988	0.943	0.876	0.824	0.606	0.456	0.219

Matthies 等人<sup>[18]</sup>提出 ALV 躲避障碍物的安全刹车距离应满足:

$$R = \frac{v^2}{2\mu g} + vT_r + B \quad (18)$$

其中  $\mu$  为地面与车轮的摩擦系数, 通常其值为 0.65;  $g$  为重力加速度;  $T_r$  为总的反应时间, 通常其值为 0.25;  $B$  为距离常量, 一般为车头到车辆坐标系原点距离加安全缓冲距离, 实验中设置距离常量为 5 m. 在非结构化环境下, ALV 速度一般不超过 25 km/h, 即 6.94 m/s. 根据式 (18), 可以求得安全刹车距离为 10.52 m. 而本文方法能在 16 m 内较为可靠地检测出负障碍物, 可以给出预警让 ALV 减速. 然后可以在 10 m 内准确给出负障碍物检测结果, 使 ALV 安全刹车. 因此, 本文提出的方法满足 ALV 在非结构化环境下安全自主导航的需求.

于传统顶装 64 线雷达的点云数据, 并采用栅格来检测负障碍物. 文 [16] 的检测方法基于 2 个侧装 32 线雷达的点云数据, 采用单扫描线分析的方法来检测负障碍物. 同时, 为验证本文提出的混合安装方式对负障碍物检测性能的提升, 还将本文方法与只采用 32 线雷达点云数据和只采用 64 线雷达点云数据的方法进行对比. 为便于对比, 只对各方法在 6 m ~ 20 m 距离段上栅格数目为 25 ~ 34 的障碍区域的召回率进行统计.

从图 16 可以发现, 本文方法的负障碍物检测性能要好于文 [14,16] 的方法. 文 [14] 方法的检测性能显著低于本文方法和文 [16] 方法的一个重要原因是其没有特征级的多帧融合, 增大了其漏报概率. 文 [16] 的检测方法基于单种检测模型, 漏检率大于本文提出的基于混合配置的多传感器负障碍物检测方法. 距离越远, 检测性能差距越大. 从图 16 还可以发现, 本文提出的基于单 64 线雷达的负障碍物检测方法在近距离处检测性能要高于本文提出的基于 32 线雷达的负障碍物检测方法. 而随着距离的增加, 本文基于 64 线雷达方法的检测性能下降较快, 逐渐低于本文基于 32 线雷达方法的检测性能. 这是因为随着距离的增加, 64 线雷达点云数据径向稀疏性越来越显著, 导致负障碍物检测性能下降较快. 本文提出的基于混合雷达的负障碍物检测方法检测性能显著优于基于单种配置雷达的检测方法. 主要原因有 2 个: 1) 多个传感器多种不同的检测模型对负障碍物的检测概率要显著高于单个传感器单个检测模型. 2) 进行贝叶斯融合时, 多传感器检测结果可以显著减少对负障碍物的确认时间. 单个传感器需要连续 3 帧检测结果才能利用贝叶斯公式对负障碍物进行确认, 而 3 个传感器单帧同时检测到负障碍物就可以通过贝叶斯公式对负障碍物进行确认.




图 16 负障碍物检测性能对比图


Fig.16 Performance comparison of negative obstacle detection

为验证本文提出的方法的性能, 将其与 2 种典型的负障碍物检测方法进行对比. 其中文 [14] 为基




### 4.3 定性分析


图 17 给出了不同场景下的负障碍物检测结果. 图 12(a) 为非结构化道路中间以及道路边缘同时存在 3 个负障碍物的场景, 图 12(b) 为泥地上存在单一负障碍物的场景, 图 12(c) 为草地上存在单一负障碍物的场景. 从图 12(a) ~ (c) 可以发现, 负障碍物在 3 个雷达的点云数据上都呈现出比较明显的负障碍物特征, 本文方法准确地给出了负障碍物的检测结果.




(a) 场景 1




(b) 场景 2



(c) 场景 3



(d) 场景 4



(e) 场景 5

图 17 负障碍物检测结果图

Fig.17 Detection results of negative obstacle

图 17(d) 中, 负障碍物因正好处在 64 线雷达 2 条扫描线之间而未能被观测到, 而 32 线雷达点云数据上负障碍物的特征比较显著. 图 17(e) 中, 负障碍物在 64 线雷达和右侧 32 线雷达的点云数据上呈现出显著的特征. 在这 2 种情况下, 本文提出的方法都准确地给出了负障碍物的检测结果. 因此本文提出的基于互补性的多传感器融合与组合特征的负障碍物检测方法具有较好的鲁棒性.

## 5 结论 (Conclusion)

本文提出了一种基于多激光雷达与组合特征的非结构化环境负障碍物检测方法. 该方法从 3 个角度来提高负障碍物检测的性能与鲁棒性. 从传感器配置角度, 提出一种具有互补性的混合激光雷达安装方式, 该方式可有效提高负障碍物的观测概率. 从负障碍检测角度, 提出基于组合特征的单激光雷达负障碍物特征点对检测方法, 该方式可提高负障碍物的检测性能与鲁棒性. 从数据融合角度, 提出基于贝叶斯准则的负障碍物时空融合方法, 可有效减少虚警与漏报现象. 实验结果表明, 本文方法能够满足自主式地面车辆对于非结构化环境下负障碍物感知的要求.

## 参考文献 (References)

- [1] Papadakis P. Terrain traversability analysis methods for unmanned ground vehicles: A survey[J]. *Engineering Applications of Artificial Intelligence*, 2013, 26(4): 1373-1385.
- [2] Matthies L, Rankin A. Negative obstacle detection by thermal signature[C]//*IEEE/RSJ International Conference on Intelligent Robots and Systems*. Piscataway, USA: IEEE, 2003: 906-913.
- [3] Hu T B, Nie Y M, Wu T, et al. Negative obstacle detection from image sequences[C]//*3rd International Conference on Digital Image Processing*. Bellingham, USA: SPIE, 2011: No.80090Y.
- [4] Rankin A L, Huertas A, Matthies L H. Night-time negative obstacle detection for off-road autonomous navigation[C]//*Proceedings of Unmanned Systems Technology IX*. Bellingham, USA: SPIE, 2007: doi:10.1117/12.720513.

- [5] 黄如林, 梁华为, 陈佳佳, 等. 基于激光雷达的无人驾驶汽车动态障碍物检测、跟踪与识别方法[J]. 机器人, 2016, 38(4): 437-443.  
Huang R L, Liang H W, Chen J J, et al. Lidar based dynamic obstacle detection, tracking and recognition method for driverless cars[J]. Robot, 2016, 38(4): 437-443.
- [6] 胡庭波, 吴涛. 一种快速鲁棒的越野环境下自主移动机器人障碍检测算法[J]. 机器人, 2011, 33(3): 287-291, 298.  
Hu T B, Wu T. A fast and robust obstacle detection algorithm for off-road autonomous mobile robots[J]. Robot, 2011, 33(3): 287-291, 298.
- [7] 黄武陵. 激光雷达在无人驾驶环境感知中的应用[J]. 单片机与嵌入式系统应用, 2016, 16(10): 3-7.  
Huang W L. Application of lidar in perception of autonomous driving environment[J]. Microcontrollers & Embedded Systems, 2016, 16(10): 3-7.
- [8] 肖强. 地面无人车辆越野环境多要素合成可通行区域检测[D]. 北京: 北京理工大学, 2015.  
Xiao Q. Multi-elements composed drivable area extraction for unmanned ground vehicles in field terrain[D]. Beijing: Beijing Institute of Technology, 2015.
- [9] Schafer H, Hach A, Proetzsch M, et al. 3D obstacle detection and avoidance in vegetated off-road terrain[C]//IEEE International Conference on Robotics and Automation. Piscataway, USA: IEEE, 2008: 923-928.
- [10] 宁火明. 未知环境中移动机器人异常检测及负高度障碍检测[D]. 长沙: 中南大学, 2007.  
Ning H M. Exceptional status detection of robot and negative elevation area detection[D]. Changsha: Central South University, 2007.
- [11] 张博, 陈慧岩, 席军强. 智能车辆非结构化路面障碍检测[J]. 汽车工程, 2009, 31(6): 526-530.  
Zhang B, Chen H Y, Xi J Q. Obstacle detection on unstructured terrain for unmanned ground vehicles[J]. Automotive Engineering, 2009, 31(6): 526-530.
- [12] Heckman N, Lalonde J F, Vandapel N, et al. Potential negative obstacle detection by occlusion labeling[C]//IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway, USA: IEEE, 2007: 2168-2173.
- [13] Larson J, Trivedi M. Lidar based off-road negative obstacle detection and analysis[C]//14th International IEEE Conference on Intelligent Transportation Systems. Piscataway, USA: IEEE, 2011: 192-197.
- [14] Morton R D, Olson E. Positive and negative obstacle detection using the HLD classifier[C]//IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway, USA: IEEE, 2011: 1579-1584.
- [15] Sinha A, Papadakis P. Mind the gap: Detection and traversability analysis of terrain gaps using LiDAR for safe robot navigation[J]. Robotica, 2013, 31(7): 1085-1101.
- [16] Shang E K, An X J, Wu T, et al. LiDAR based negative obstacle detection for field autonomous land vehicles[J]. Journal of Field Robotics, 2016, 33(5): 591-617.
- [17] Ester M, Kriegel H P, Sander J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//2nd International Conference Knowledge Discovery and Data Mining. Menlo Park, USA: AAAI, 1996: 226-231.
- [18] Matthies L, Grandjean P. Stochastic performance, modeling and evaluation of obstacle detectability with imaging range sensors[J]. IEEE Transactions on Robotics and Automation, 1994, 10(6): 783-792.

#### 作者简介:

刘家银 (1986-), 男, 博士生. 研究领域: 智能机器人, 环境理解, 数据融合.

唐振民 (1961-), 男, 博士, 教授. 研究领域: 智能机器人与智能检测, 图像处理技术.

王安东 (1990-), 男, 博士生. 研究领域: 机器学习, 张量分析.