

16 线雷达点云的实时小障碍物检测研究

韩莹¹, 袁静^{1*}, 司江胜¹, 杨德贺²

¹ 防灾科技学院信息工程学院, 河北 廊坊 065201;

² 应急管理部国家自然灾害防治研究院, 北京 100085

摘要 铁路是运输系统中的主要交通工具之一, 而铁路的安全隐患主要来自于铁轨上的入侵障碍物, 如危岩、动物和行人等, 因此障碍物实时检测预警技术必不可少。采用 16 线三维激光雷达采集数据, 实现了点云成像。基于八叉树方法对背景点云和实时采集的点云进行空间体素化, 并进行差分运算, 然后通过统计滤波和半径滤波对点云进行去噪处理, 实现了小目标障碍物的实时检测。研究结果为 16 线三维激光雷达扫描系统的数据采集提供了参考。

关键词 遥感; 16 线激光雷达; 三维点云; 小障碍物; 实时检测

中图分类号 TN958.98

文献标志码 A

doi: 10.3788/LOP202158.1228001

Real-Time Detection of Small Obstacles Based on 16-Ray Lidar Point Cloud

Han Ying¹, Yuan Jing^{1*}, Si Jiangsheng¹, Yang Dehe²

¹ College of Information Engineering, Institute of Disaster Prevention, Langfang, Hebei 065201, China;

² National Institute of Natural Hazards, Ministry of Emergency Management of China, Beijing 100085, China

Abstract The railway system is one of the major means of transport in the transportation system, and the hidden danger to railway safety is mainly from the intrusion obstacles on the railway, such as dangerous rocks, animals, and pedestrians, and thus the technology for real-time detection of small obstacles is essential. In this paper, the 16-ray 3D lidar is used to collect data and realize point cloud imaging. The background point cloud and the point cloud collected in real time are first spatially voxelized based on the octree method, and then difference operations are performed on them. In addition, the statistical filtering and radius filtering are used to denoise the point cloud. Finally, the real-time detection of small target obstacles is realized. The research results provide some references for the data collection of a 16-ray 3D lidar scanning system.

Key words remote sensing; 16-ray lidar; 3D point cloud; small obstacles; real-time detection

OCIS codes 280.3640; 100.4996; 100.6890

1 引言

自 20 世纪 80 年代以来, 采用点云形式表示客观世界的物理模型得到了广泛的理论研究与实际应用。获取物理模型三维点云的常用手段是激光雷达, 雷达具有高精度、高分辨率、远距离和大范围等

优点, 可快速、实时获取被测物体的三维空间信息^[1], 被广泛应用于医疗、农业、机器人导航^[2]、家政机器人^[3]、自动驾驶、虚拟现实^[4]和地质勘探等各种领域。采用三维激光扫描技术采集点云数据, 具有高速度、高精度和可量测等优点, 已成为当前获取三维数据的热门手段^[5]。与基于图像的检测相比, 雷

收稿日期: 2020-09-24; 修回日期: 2020-09-30; 录用日期: 2020-10-14

基金项目: 中央高校基本科研业务费专项资金(ZY20180120)

* E-mail: yuanjing20110824@sina.com

达提供了可靠的深度信息,可精确定位对象并提取它们的特征形状^[6],其优点是直接测量所包含对象间的距离^[7]。因此,用于自动驾驶的目标检测算法可估计不同物体在三维空间中的位置和航向^[8-15]。

铁路是重要的交通工具之一,但铁路沿线环境复杂。铁路系统主要的安全问题是危险的外来物质入侵,如泥石流、坠落的岩石以及行人、动物等运动物体。随着视频监控技术的发展,铁路沿线事故多发线路上都安装了视频设备,需要人工判断是否有异物入侵。然而,人工检测容易丢失数据,自动化程度低,因此自动检测技术必不可少。近年来,随着信息技术的飞速发展,国内外开始关注铁路障碍物检测新技术的研究。视频监控和图像处理技术已应用于铁路异物检测中^[16-18],但摄像机的图像质量受到环境的影响,如天气和光线,在实际应用中受到很大的限制。为了检测异物入侵,可在关键区域的轨道两侧安装多传感器系统^[19-20],但这种方法需要对沿线设备进行定期检查,维护工作量大。移动检测方法可以定期扫描和检测障碍物^[21],但该系统中使用的主要设备是摄像机,摄像机会受到距离和光线的影响,因此没有得到普及。

激光雷达二维扫描检测新技术在铁道线路安全防护系统中得到了应用,该技术采用激光雷达在铁路轨道上方的一定高度处进行扫描,以识别轨道平面上的物体^[22]。然而,这种平面扫描模式存在许多缺陷。第一,因为它是平行于轨道平面进行扫描的,只能获得一个信息平面,所以无法获得障碍物的立体数据,错误率很高。第二,在施工和后期维护中,二维平面扫描方法的扫描平面高度应经常调整,工作量大,维护成本很高。第三,在平面扫描中,前端的小障碍物会阻挡后面的大障碍物,这可能导致漏报。因此将激光雷达三维扫描技术引入到铁路安全防护系统中是非常有必要的,三维扫描方法可以扫描和成像整个防御区,并获得防御区的三维点云图像信息。它可以实现铁道场景再现,获取铁道上方障碍物的各种数据信息,如位置、高度、运动等,具有较高的目标检测能力,并结合算法解决入侵报警问题,从而实现铁路系统的自动保护和报警。

根据国际光学工程学会(SPIE)的定义,在 $256 \text{ pixel} \times 256 \text{ pixel}$ 图像中,小目标面积小于 80 pixel^2 。本文提出了一种基于 16 线激光雷达的障碍物自动检测技术,实现了小目标障碍物的

实时检测,为防止异物入侵铁路提供了可靠的技术。

2 点云数据的采集和预处理

图 1 为障碍物检测的应用场景,数据处理过程主要由四个阶段组成。第一阶段是采集数据和点云成像处理,这一阶段主要是对所采集数据进行坐标变换,使得点云数据能覆盖整个防护区的轨道面。第二阶段是点云数据的分析处理,通过直通滤波,将数据分析重点放在轨道面上方的空间中以减少系统计算量,从而提高系统的计算速度,保证实时性。第三阶段是对实时点云和背景点云进行差分运算,这一阶段利用检测区域内铁路轨道物理空间的不变性,只提取新增点云。第四阶段是障碍物提取,这一阶段是在第三阶段的基础上,使用统计滤波和半径滤波进行点云去噪,从而识别障碍物,获取障碍物的空间位置信息。

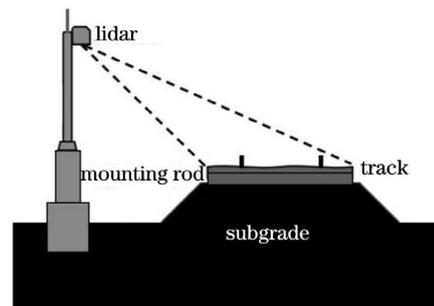


图 1 铁路检测场景

Fig. 1 Scenery for railway detection

2.1 16 线雷达装置及坐标转换

常用的激光雷达为机械式激光雷达,由若干组可以旋转的激光发射器和接收器组成,每个发射器发射一条激光束,称之为扫描线。目前主要有 16 线、32 线和 64 线激光雷达^[23]。本实验使用的是北京北科天绘科技有限公司 R-Fans-16 激光雷达,有 16 条激光扫描线, 360° 扫描,实现三维探测成像,各条激光扫描线的角度如图 2 所示。

R-Fans-16 激光雷达的坐标系相对于设备外壳结构固定不变,坐标系的原点 o 位于设备中心轴上, z 轴垂直于 R-Fans-16 底面, x 轴沿设备侧面引出缆线方向,坐标系如图 3(a)所示。

计算某一方向上的点坐标 $A(x, y, z)$,需要点的回波距离 R 、垂直角度 V_t 、水平角度 H_b 、转盘角度 ω_t 以及点坐标水平偏移角 ϕ ,其中角度示意图如图 3(b)所示。点云从极坐标系统转换到笛卡尔坐标系统的转换公式为

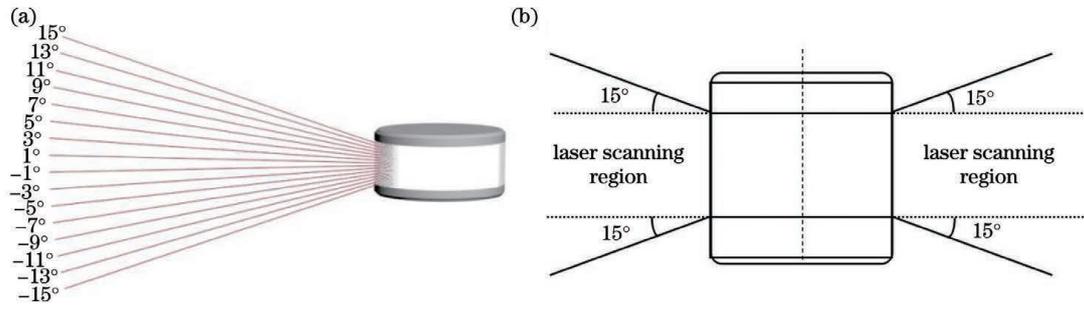


图 2 R-Fans-16 激光雷达示意图。(a)雷达模型;(b)扫描角度

Fig. 2 Schematic of R-Fans-16 lidar. (a) Lidar model; (b) scanning angle

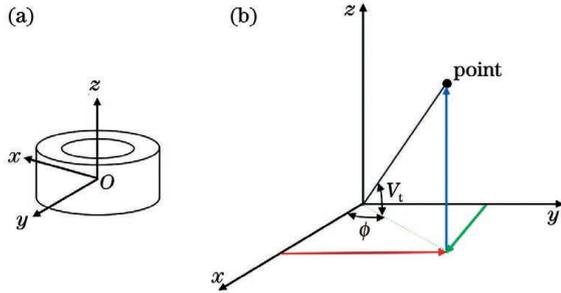


图 3 R-Fans-16 坐标系及参数示意图。(a) R-Fans-16 坐标系;(b)角度示意图

Fig. 3 R-Fans-16 coordinate system and schematic of parameters. (a) R-Fans-16 coordinate system; (b) schematic of angles

$$\begin{aligned} \phi &= -\omega_t - \omega \times \Delta t - H_b, & (1) \\ x &= R \times \cos(V_t) \times \cos(\phi), & (2) \\ y &= R \times \cos(V_t) \times \sin(\phi), & (3) \\ z &= R \times \sin(V_t), & (4) \end{aligned}$$

式中: ω 为雷达旋转速度; Δt 为雷达旋转时间。

2.2 点云成像

当雷达旋转起来时,利用点云坐标计算,绘制由 16 条平行激光线构成的点云图,如图 4 所示。

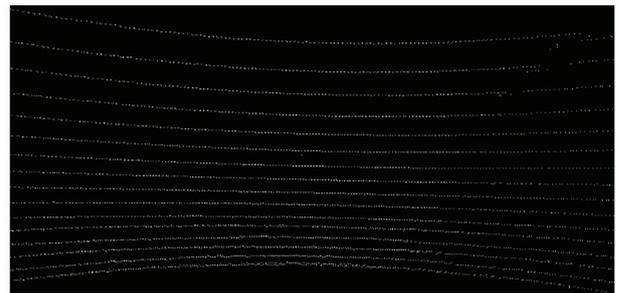


图 4 场景的扫描点云图

Fig. 4 Scanning point cloud map of scene

如图 4 所示,线条之间的黑色区域是雷达无法扫描到的,称为“黑洞”。为了去除黑洞,利用一个角位移平台带动雷达一起旋转,扩大每根雷达线的扫描区域,角位移平台的结构如图 5 所示。

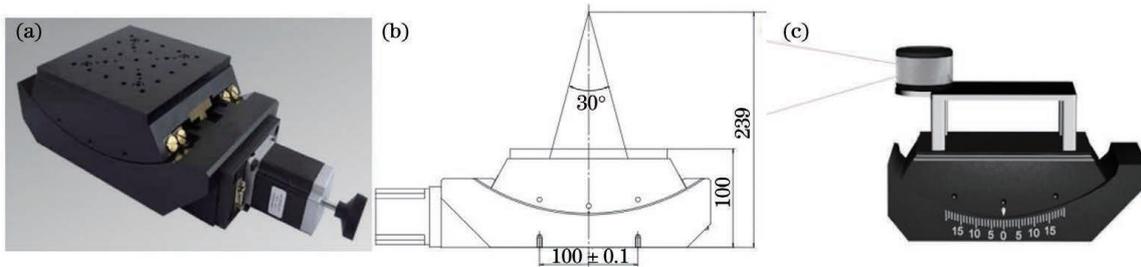


图 5 固定在角位移平台上的雷达。(a)角位移平台;(b)角位移平台的坐标中心;(c)平台及雷达

Fig. 5 Lidar fixed on angular displacement platform. (a) Angular displacement platform; (b) coordinate center of angular displacement platform; (c) platform and lidar

在角位移平台转动 2° 的情况下,雷达旋转得到的点云图如图 6 所示,可以看出,在距离雷达较近的地方,黑洞已经弥补,但是较远处仍然存在黑洞,并且随着距离雷达位置越远,黑洞越大,这说明角位移平台转动 2° 并不能完全弥补黑洞,需要根据实际工程需求,设定角位移平台旋转角度以弥补黑洞。

2.3 铁轨障碍物检测场景

根据实际工程需要,铁轨两旁每 50 m 安装一个高度为 3 m 的 R-Fans-16 实时检测雷达,监控区域如图 7 所示,其中 WQ 为雷达覆盖范围靠近雷达立杆的一条边。在投入实际应用之前,在模拟环境下采集测试数据,根据实际的工程空间需求设置模拟空间环境,使得模拟环境与实际应用环境相似。

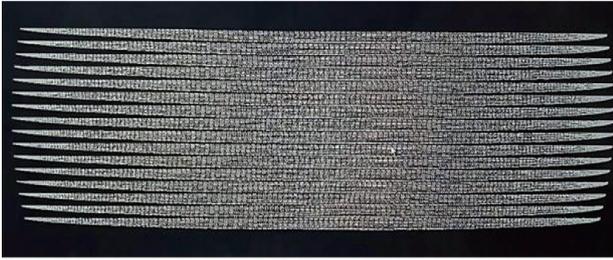


图 6 角位移平台旋转 2° 后的点云图

Fig. 6 Point cloud map of angular displacement platform rotated by 2°

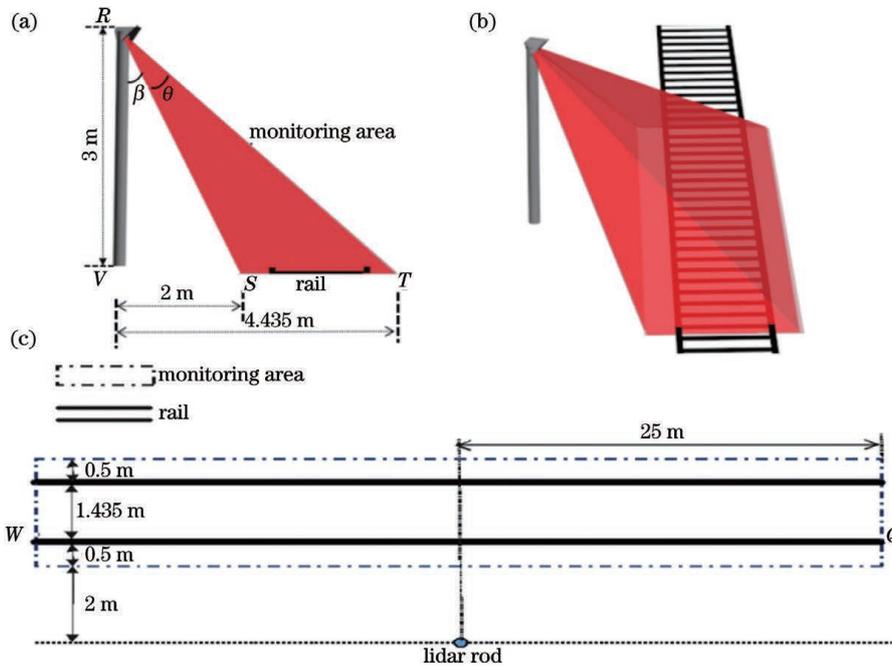


图 7 铁路雷达监控场景。(a)前视图;(b)左视图;(c)俯视图

Fig. 7 Scenery for lidar monitoring railway. (a) Front view; (b) left view; (c) top view

已知 $L_{VS}=2\text{ m}$, $L_{RV}=3\text{ m}$, $L_{VT}=4.435\text{ m}$, 通过计算得到 $\beta=33.69^\circ$, $\theta=22.32^\circ$ 。

由于 16 线雷达激光线覆盖的角度范围为 $-15^\circ\sim 15^\circ$, 如图 2(b) 所示, 雷达需要倾斜 μ 角度,

使得 $15^\circ + \mu > 90^\circ - \beta$ 且 $\mu - 15^\circ < \beta + \theta$, 求得 $\mu > 41.31^\circ$ 且 $\mu < 71.01^\circ$ 。因此, 在满足要求的情况下安装了一个角度值为 42.95° 的三角基座, 如图 8 所示, 以保证雷达轨道扫描覆盖范围。

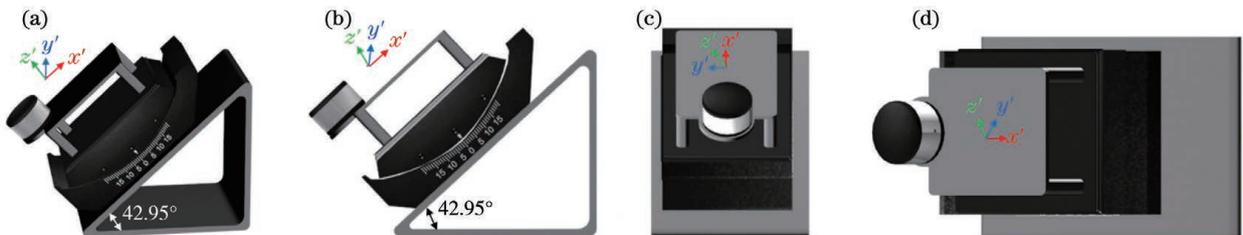


图 8 带三角基座的雷达系统。(a)透视图;(b)前视图;(c)左视图;(d)顶视图

Fig. 8 Radar system with triangular base. (a) Perspective view; (b) front view; (c) left view; (d) top view

安装三角基座后, 场景中雷达的俯视角范围是 $57.95^\circ\sim 27.95^\circ$ 。

2.4 去黑洞

2.4.1 添加角位移平台

添加角位移平台的目的是让角位移平台带动雷

达一起转动,以扩大扫描区域,从而弥补点云图中的黑洞。雷达一边自转,一边随着角位移平台一起旋转,这个过程中平台基座的中心点位置不变。为了计算方便,把点云坐标系从雷达坐标系转换到角

位移平台坐标系,如图 9 所示。其中, O' 为角位移平台的坐标中心点, O 为雷达坐标中心。 0.0965 m 为两个坐标系中心点 O' 和 O 之间的距离,该值是通过硬件设备测量计算获得的。

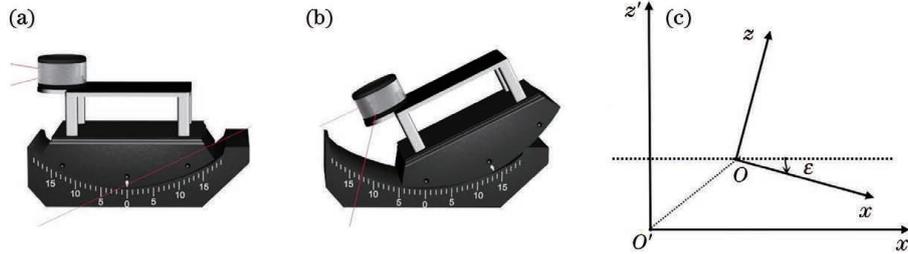


图 9 雷达转动示意图及坐标转换系统。(a)添加了角位移平台的雷达;(b)雷达自转同时随着角位移平台转动;(c)坐标转换系统

Fig. 9 Schematic of lidar rotation and coordinate transformation system. (a) Radar with added angular displacement platform; (b) lidar self-rotation and simultaneous rotation with angular system displacement platform; (c) coordinate transformation system

坐标系变换公式为

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & t_x \\ 0 & 1 & 0 & t_y \\ 0 & 0 & 1 & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \cos \epsilon & 0 & -\sin \epsilon & 0 \\ 0 & 1 & 0 & 0 \\ \sin \epsilon & 0 & \cos \epsilon & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}, \quad (7)$$

式中: t_x 为雷达中心 O 与角位移平台中心 O' 之间的水平距离, $t_x=0.0965\cos \epsilon$; t_y 为雷达中心 O 与角位移平台中心 O' 之间的纵深距离, $t_y=0$; t_z 为雷达中心 O 与角位移平台中心 O' 之间的垂直距离, $t_z=0.0965\sin \epsilon$; ϵ 为角位移平台的旋转角度。由(7)式,有

$$\begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} = \begin{bmatrix} \cos \epsilon & 0 & \sin \epsilon & -0.0965 \\ 0 & 1 & 0 & 0 \\ -\sin \epsilon & 0 & \cos \epsilon & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix}. \quad (8)$$

2.4.2 设置角位移旋转角度

铁轨障碍物检测应用场景如图 7 所示,已知 $L_{RV}=3\text{ m}$, $|WQ|=50\text{ m}$, $L_{VS}=2\text{ m}$,轨道宽度是 1.435 m ,为了保证障碍物检测覆盖范围,在轨道现有宽度的基础上,两侧宽度各增加 0.5 m 。雷达扫描场景的模拟如图 10(a)所示。

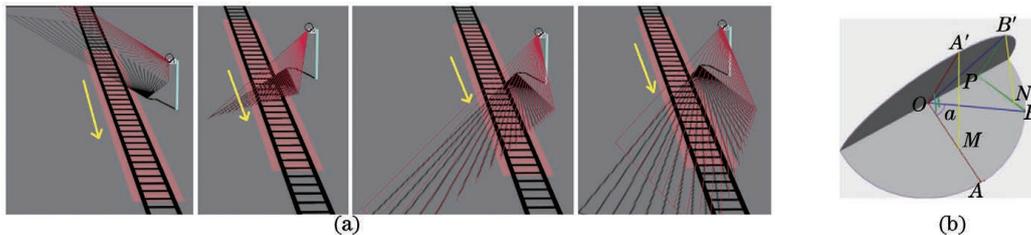


图 10 雷达扫描过程中产生的角度变化。(a)雷达扫描场景的模拟;(b)角位移平台带动雷达转动与雷达自转的关系
Fig. 10 Angle change during lidar scanning process. (a) Simulation of lidar scanning scene; (b) relationship between lidar self-rotation and lidar rotation driven by angular displacement platform

如图 10(b)所示, t 为雷达随着角位移平台旋转的角度, a 为 B 点远离 A 点的角度。对于 A 这个位置,当角位移平台带动雷达旋转为 t 角度时,雷达激光线从 A 转到 A' ,雷达 A 点上下移动的垂直距离 $L_{a1m}=|A'M|$,雷达 B 点上下移动的垂直距离 $L_{b1n}=|B'N|$ 。用 L_{oa1} 表示 O 到 A' 的距离, L_{pb1} 表示 P 到 B' 距离, L_{pb} 表示 P 到 B 的距离, L_{ob} 表示 O 到 B 的距离, L_{bn1} 表示 B' 到 N 的距离,因此有

$$L_{a1m} = L_{oa1} \sin(t), \quad (9)$$

$$L_{b1n} = L_{pb1} \sin(t), \quad (10)$$

$$L_{pb1} = L_{pb} = L_{ob} \cos(\alpha) = L_{oa1} \cos(\alpha), \quad (11)$$

$$L_{bn1} = L_{oa1} \sin(t) \cos(\alpha). \quad (12)$$

由(9)~(12)式可以推知,角位移平台的旋转角度 θ 与雷达的旋转角度 t 的关系为 $\theta \times \cos a = t$,其中 α 为雷达激光线从 A 点偏移到 B 点的自转角度。随着 α 的增大,雷达的旋转角度减小。已知相邻的

雷达激光线之间的角度差为 2° , 在雷达自转过程中, 为了弥补这个 2° 对应的黑洞, 需要满足

$$\theta \times \cos \alpha = 2. \quad (13)$$

根据图 7 可以计算得知, 最大偏移角度 α 为 81.77° , 从而计算得到 θ 为 13.97° , 即角位移平台至少需要旋转 13.97° 才能来能弥补场景中 25 m 处的黑洞。设置平台旋转 14° 后, 扫描模拟场景所得到的点云图如图 11 所示, 可以看出, 25 m 处的黑洞已经得到弥补。



图 11 角位移平台旋转 14° 后的点云图

Fig. 11 Point cloud map of angular displacement platform rotated by 14°

3 障碍物检测

3.1 数据获取

3.1.1 背景点云的采集

为了在雷达射线方向上达到 $1/0.1^\circ$ 的点云密度, 选择 R-Fans-16 激光雷达的转动频率为 20 Hz。此外, 根据 R-Fans-16 雷达的特性, 每 1.7 ms 接收一个点数据包。每个点数据包有 12 组, 每组 32 个点。如图 7 所示, 场景需要检测的角度范围为

$-81.77^\circ \sim 81.77^\circ$, 为了确保检测效果, 激光雷达的检测范围设置为 $-83^\circ \sim 83^\circ$ 。

为了使得点云密度达到 $1/0.1^\circ$, 角位移平台需要每秒旋转 2° , 即转动速度为 $2^\circ/\text{s}$ 。由前面的推导可知, 角位移平台旋转 14° 才能弥补 25 m 处的黑洞, 所需时间为 7 s。文中把角位移 14° 的旋转称为一趟扫描, 得到一副点云图。

激光雷达在场景扫描过程中, 不可避免地会出现数据丢失和噪声。为了减小噪声造成的误差并弥补丢失的数据, 则需要获得更多的采样点, 因此在生成背景点云时, 通常采用多次扫描结果叠加的方法。

在多趟扫描过程中, 必然存在大量的重复点, 直接删除角度相同、回波距离完全相同的点, 而对于角度相同、回波距离不同的点, 则采用均值法进行剔除。

设第 i 趟重复扫描的平均回波距离为 E_i , 计算公式为

$$E_i = \frac{E_{i-1} \cdot (i-1) + X_i}{i}, \quad (14)$$

式中: E_{i-1} 为第 $i-1$ 趟扫描结束时回波距离的平均值, 当 $i=1$ 时, $E_1=0$; i 为重复扫描的次数; X_i 为同一水平角度下的不同回波距离, 由第 i 趟扫描得到。

另外一种处理重复数据的方法是简单删除法, 也就是对于角度相同、回波距离不同的点, 直接取多趟扫描中最后一趟的值。如图 12 所示。图 12(a) 所示为直接删除法去重后的效果图, 图 12(b) 所示为均值法去重后的效果图, 可以看出, 均值法去重后的线条更加平滑, 效果优于直接删除法。本文在多趟扫描获取背景点云数据时, 采用的是均值法去重。

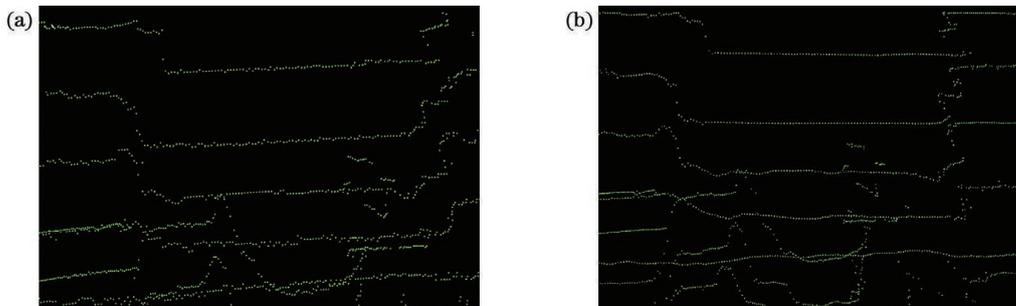


图 12 不同方法去重后的效果。(a)直接删除法;(b)均值法

Fig. 12 Effects after deletion of duplicate data by different methods. (a) Direct deletion method; (b) mean method

3.1.2 实时点云采集

在实际检测过程中, 考虑到障碍物检测的实时性, 采用一趟扫描收集的点云作为实时检测数据, 即以角位移平台旋转 14° , 用时 7 s 采集的点云作为实时检测数据。与背景数据采集一样, 在 7 s 内获取

的点云数据同样存在重复现象, 也使用均值法去重。

3.2 直通滤波法处理点云数据

采集完背景点云和实时点云后, 下一步开始进行障碍物检测操作。障碍物检测的流程如图 13 所

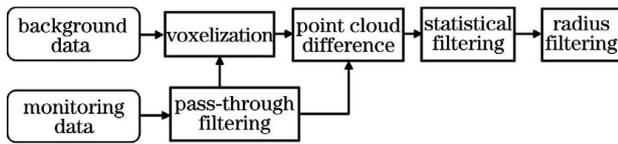


图 13 障碍物的检测流程图

Fig. 13 Flow chart of obstacle detection

示,首先对获取的背景点云和直通滤波后的实时点



图 14 直通滤波后的结果

Fig. 14 Pass-through filtering result

3.3 基于八叉树的体素化

根据采集的背景数据与实时数据之间的空间对应关系,采用八叉树体素化^[24-26]对三维区域进行点云分割。在这种八叉树形式中,空间分解的方法是一致的,所有节点均被分成 8 个相同的子节点,如图 15 所示。

在八叉树体素化的基础上,对实时点云和背景点云进行差分处理,只保留新增的数据,如图 16 所示。16(a)所示是背景点云,16(b)所示是实时检测包含障碍物的实时点云。在 16(b)上执行直通滤波后,分别对高于地面的背景点云和实时点云进行体素化处理及差分处理,结果如 16(c)所示。

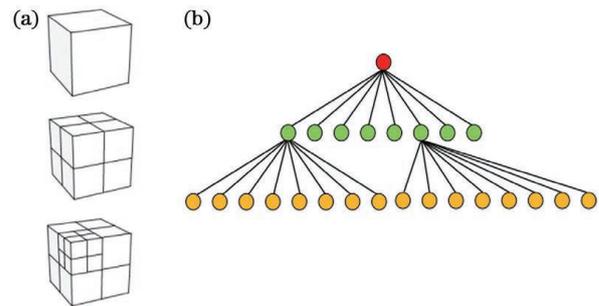


图 15 基于八叉树体素化的三维区域分割。(a) 空间的三维表示;(b)八叉树层次结构

Fig. 15 3D region segmentation based on octree voxelization. (a) 3D representation of space; (b) octree hierarchical structure

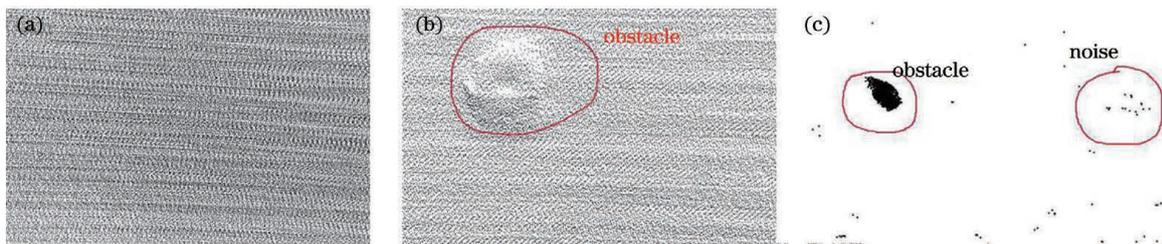


图 16 点云差分处理示意图。(a)背景点云;(b)实时检测的点云;(c)差分处理后的结果

Fig. 16 Schematic of point cloud difference treatment. (a) Background point cloud; (b) point cloud for real-time detection; (c) result after difference treatment

3.4 高斯统计滤波

对于点云,噪声滤波的效果将直接影响后期障碍物的识别。本文通过高斯统计滤波,对前面所得到的差分后的新增点云进行去噪处理。

通过分析离散点的空间分布特征,可以发现,离散点通常远离主点云或分散在主点云周围,而主点云相对集中密集。因此利用这个空间分布特征,使用统计滤波算法来分析和过滤离散点,具体操作如下。

假设离散点的点云数据集为 $Y = \{y_j, j = 1,$

$2, \dots, m\}$, 过滤后的离散点的数据集为 $Y' = \{y'_k, k = 1, 2, \dots, p\}$, 其中 m 为点云数据集中点的数量, p 为过滤后数据集中点的数量。对于任意点 y_j , S_j 表示它到其他 k 个相邻点的平均距离。统计滤波算法是假设 y' 中所有点的 S_j 服从高斯分布, S_j 的均值为 μ_1 , 标准差为 σ_1 , 表达式分别为

$$\mu_1 = \frac{\sum_{j=1}^m S_j}{m}, \quad (15)$$

$$\sigma_1 = \frac{\sum_{j=1}^m (S_j - \mu_1)^2}{m} \quad (16)$$

点云中所有超出 $(\mu_1 - \epsilon_1 \cdot \sigma_1, \mu_1 + \epsilon_1 \cdot \sigma_1)$ 范围的点都被视为异常值, 将这样的点抛弃, 其中 ϵ_1

是用来控制截取正态分布区域范围大小的。在实验中, 当设置不同数目 k 的相邻点和不同的 ϵ_1 值时, 降噪效果不同, 如图 17 所示, 可以看出, $k=20, \epsilon_1=0.1$ 时的降噪效果最好。本文实验采用 $k=20, \epsilon_1=0.1$ 。

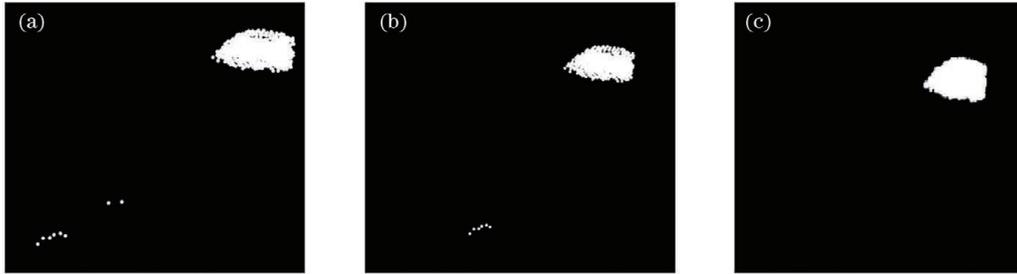


图 17 不同条件下的统计滤波结果。(a) $k=20, \epsilon_1=1$; (b) $k=5, \epsilon_1=0.1$; (c) $k=20, \epsilon_1=0.1$

Fig. 17 Statistical filtering results under different conditions. (a) $k=20, \epsilon_1=1$; (b) $k=5, \epsilon_1=0.1$; (c) $k=20, \epsilon_1=0.1$

3.5 半径滤波

在实际的实验测试中, 即使是使用了高斯滤波, 仍然存在很多离散点。为了更精确地识别障碍物, 在高斯统计滤波后, 再采用半径滤波对数据进行处理, 最终剩余未被删除的点云被确定为障碍物。

道路宽度与铁路防区宽度相同, 根据图 7 配置激光雷达的位置和高度。三维激光雷达的测量场景如图 18(a) 所示, 所得到的对应的点云如图 18(b) 所示, 障碍物的实物图如图 18(c) 所示。

4 模拟实验

分别使用 16 线雷达的 1 条扫描线、6 条扫描线、8 条扫描线和 16 条扫描线, 对模拟场景进行扫描测试。因为在采集数据和处理数据上, 6 条线、8 条线和 16 条线的原理相同, 所以下面只对 1 条线和 16 条线采集的点云数据进行比较和分析。

本实验是在模拟环境中进行的, 如图 18 所示。

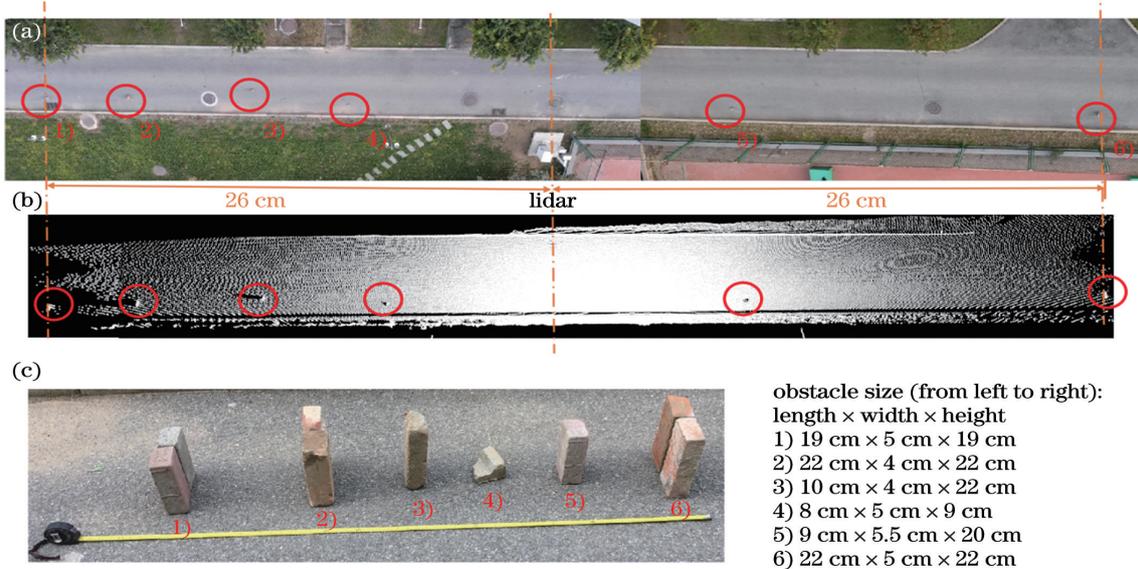


图 18 激光雷达测量对象和点云图。(a) 三维激光雷达的测量场景; (b) 点云图; (c) 障碍物实物图

Fig. 18 Lidar measurement objects and point cloud map. (a) 3D lidar measurement scene; (b) point cloud map; (c) practical obstacle images

4.1 16 线点云障碍物检测

按照前面所述的障碍物检测方法, 同时使用 16 条扫描线收集的点云, 进行障碍物检测, 结果如图 19 所示, 编号标记的物体为检测到的障碍物。

其中, 八叉树的体素参数大小设置为 24 cm, 统计滤波算法的相邻点参数 k 值为 20, ϵ_1 值为 0.1; 半径滤波器的半径参数为 8 cm, 相邻点数设置为 21。

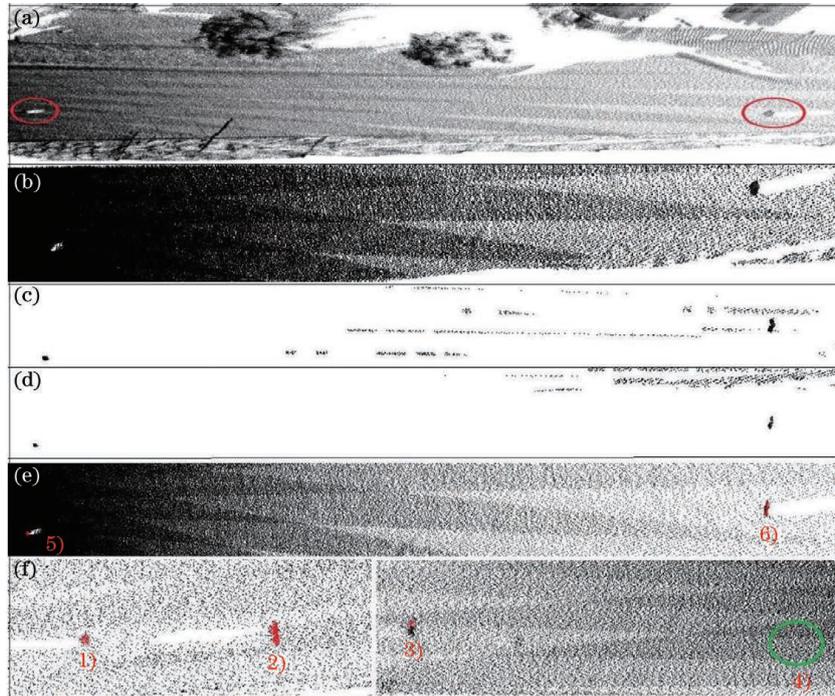


图 19 基于 16 线点云的障碍物检测结果。(a)雷达右侧实时检测的点云;(b)直通滤波后的结果;(c)差分处理后的结果;(d)去噪后的结果;(e)右侧障碍物的标记结果;(f)左侧障碍物的标记结果

Fig. 19 Results of obstacle detection based on 16-ray point cloud. (a) Point cloud of real-time detection on right of lidar; (b) result after pass-through filtering; (c) result after difference treatment; (d) result after denoising; (e) marking result of obstacle on right; (f) marking result of obstacle on left

4.2 1 线点云障碍物检测

1 线点云只使用 16 线点云的 0° 射线采集数据。为了达到 $1/0.1^\circ$ 的点云密度和 20 Hz 的雷达转动频率,角位移平台的旋转角速度设置为 $2^\circ/s$ 。

对于 16 线雷达中的 0° 射线,角位移平台旋转角度变化和 0° 射线旋转角度变化相同。为了使单线点

云覆盖整个防御区(如图 7 所示),角位移平台需要驱动雷达旋转 30° ,因此扫描完整防御区所需的时间为 15 s。以多趟扫描采集的数据集作为背景点云,对于多趟采集数据中的重复数据,采用均值法去重。

基于 1 线雷达获取的点云进行障碍物检测,结果如图 20 所示。其中,在进行基于八叉树体素化时,

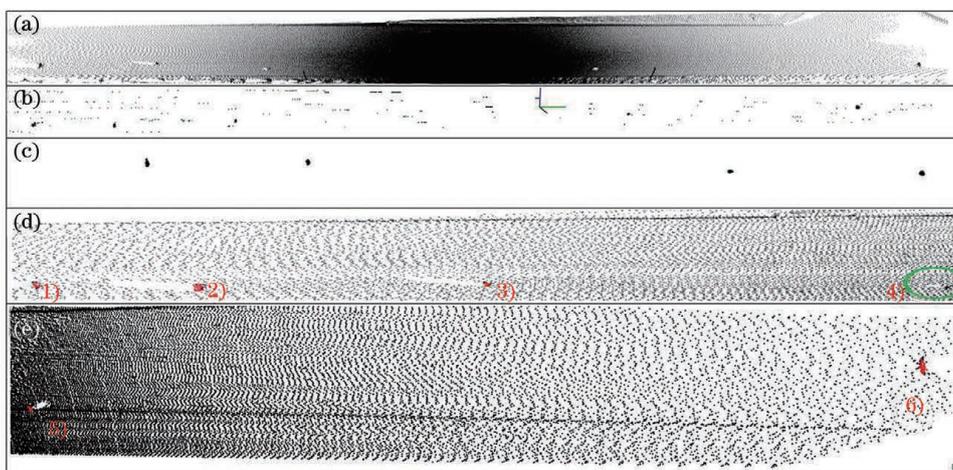


图 20 基于 1 线点云的障碍物检测结果。(a)直通滤波后的结果;(b)差分处理后的结果;(c)去噪后的结果;(d)左侧障碍物的标记结果;(e)右侧障碍物的标记结果

Fig. 20 Results of obstacle detection based on 1-ray point cloud. (a) Result after pass-through filtering; (b) result after difference treatment; (c) result after denoising; (d) marking result of obstacle on left; (e) marking result of obstacle on right

体素大小为 24 cm, 高斯统计滤波的 k 值设置为 20, ϵ_1 为 0.1, 半径滤波器的半径为 32 cm, 相邻点数为 20。

4.3 实验结果分析

从实验结果可以看到, 通过处理 1 线点云和 16 线点云数据, 都检测到了场景中的 1 号、2 号、3 号、5 号和 6 号物体。由此可以推断出, 在距离雷达 26 m 的范围内, 只要长度、宽度或者高度超过了 10 cm, 物体均能被检测到。对于模拟场景中的 4 号物体, 因为其长度、宽度和高度均小于 10 cm, 其未被检测出来, 因此后续工作要对障碍物的检测算法进行进一步的研究和优化, 提高小物体检测的准确率。

对于障碍物的检测性能来说, 16 线和 1 线的算法检测性能基本相同, 但是 16 线能在 7 s 内完成整个区域的扫描, 而 1 线需要 15 s 才能完成整个区域的扫描。因此 16 线在时间上优于 1 线, 在紧急情况下, 成像时间也是一个非常重要的指标。

5 讨论

原始点云的过滤是点云处理过程中的一个关键步骤。由于目标识别是从点云序列开始的^[27], 对点云序列进行滤波, 有助于提高物体识别的性能和



图 22 1 线点云和 16 线点云的比较。(a) 1 条线点云; (b) 16 条线点云

Fig. 22 Comparison between 1-ray point cloud and 16-ray point cloud. (a) 1-line point cloud; (b) 16-line point cloud

总之, 点云数据预处理是非常重要的, 它将直接影响后期障碍物检测的准确性。

6 结论

采用 16 线激光雷达模拟了直道铁路的铁轨场景。通过数据采集和预处理, 实现了点云成像。通过二叉树对点云进行了体素化, 并结合使用各种去噪技术, 最终识别出场景中长度或宽度或高度超过 10 cm 的小目标, 实现了小目标障碍物的实时检测。

下一步工作是对弯道铁路场景进行扫描与检测设计。另外, 目前模拟场景中障碍物设置的是反射率较低的物体。反射率非常高的障碍物以及遮挡障碍物的检测将是后期工作的重点。

精度。

本文检测结果的准确性主要受两个方面的影响: 1) 数据采集过程中去除重复点的操作; 2) 点云滤波算法。障碍物的 16 线实时检测点云如图 21 所示, 4 号物体在进行差分处理之前就无法看到。这是因为 16 线雷达的每条线的噪声被叠加, 噪声不断增大, 小物体的点云数据被平均。

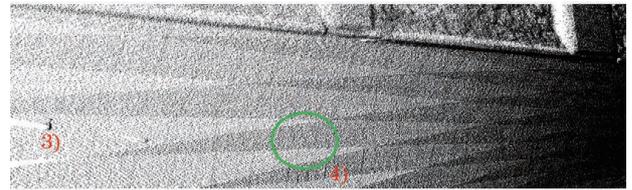


图 21 障碍物的 16 线实时检测点云

Fig. 21 16-ray point cloud for real-time detection of obstacle

另外, 对比 1 线点云图和 16 线点云图, 可以直观看到, 16 线点云有明显的层次感, 如图 22 所示。这是因为 16 线的每一条线都有不同误差, 噪声为这 16 条线的误差的多次叠加结果。如果仅对单个防御区的障碍物进行检测, 则背景点云和实时检测点云的差分计算对障碍物识别结果的影响不大。但是, 如果对相邻两个防御区进行点云拼接, 16 线点云拼接会有较大难度。

参考文献

- [1] Hu Y W, Wang J J, Fan Y Y, et al. LiDAR-based three-dimensional modeling and volume calculation for space objects [J]. Chinese Journal of Lasers, 2020, 47(5): 0510001.
胡燕威, 王建军, 范媛媛, 等. 基于激光雷达的空间物体三维建模与体积计算 [J]. 中国激光, 2020, 47(5): 0510001.
- [2] Ojeda R G, Briaies J, Jimenez J G, et al. PL-SVO: semi-direct monocular visual odometry by combining points and line segments [C] // 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 9-14, 2016, Daejeon, Korea (South). New York: IEEE, 2016: 4211-4216.

- [3] Oh Y J, Watanabe Y. Development of small robot for home floor cleaning[C]//Proceedings of the 41st SICE Annual Conference SICE 2002, August 5-7, 2002, Osaka, Japan. New York: IEEE Press, 2002: 3222-3223.
- [4] Park Y, Lepetit V, Woo W, et al. Multiple 3D object tracking for augmented reality[C]//2008 7th IEEE/ACM International Symposium on Mixed and Augmented Reality, September 15-18, 2008, Cambridge, UK. New York: IEEE Press, 2008: 117-120.
- [5] Zhao M N, Hua X H, Feng S Q, et al. Information extraction of buildings, doors, and windows based on point cloud slices[J]. Chinese Journal of Lasers, 2020, 47(6): 0604002.
赵梦娜, 花向红, 冯绍权, 等. 基于点云切片的建筑物门窗信息提取[J]. 中国激光, 2020, 47(6): 0604002.
- [6] Chen X Z, Ma H M, Wan J, et al. Multi-view 3D object detection network for autonomous driving[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6526-6534.
- [7] Geiger A, Lenz P, Urtasun R, et al. Are we ready for autonomous driving? The KITTI vision benchmark suite [C] // 2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE Press, 2012: 3354-3361.
- [8] Cao H W, Yang L H, Lin J R, et al. Networking method of distributed measurement network fused with autonomous navigation information[J]. Laser & Optoelectronics Progress, 2020, 57(15): 151201.
曹瀚文, 杨凌辉, 林嘉睿, 等. 融合自主导航信息的分布式测量网络组网方法[J]. 激光与电子学进展, 2020, 57(15): 151201.
- [9] Zhou Y, Tuzel O. VoxelNet: end-to-end learning for point cloud based 3D object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4490-4499.
- [10] Engelcke M, Rao D, Wang D Z, et al. Vote3Deep: fast object detection in 3D point clouds using efficient convolutional neural networks[C]//2017 IEEE International Conference on Robotics and Automation (ICRA), May 29-June 3, 2017, Singapore. New York: IEEE Press, 2017: 1355-1361.
- [11] Qi C R, Liu W, Wu C X, et al. Frustum PointNets for 3D object detection from RGB-D data[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 918-927.
- [12] Wang S K, Sun Y X, Liu C J, et al. PointTrackNet: an end-to-end network for 3-D object detection and tracking from point clouds[J]. IEEE Robotics and Automation Letters, 2020, 5(2): 3206-3212.
- [13] Ku J, Mozifian M, Lee J, et al. Joint 3D proposal generation and object detection from view aggregation [C] // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2018: 1-8.
- [14] Li B, Zhang T L, Xia T, et al. Vehicle detection from 3D lidar using fully convolutional network[C]//Robotics: Science and Systems XII, August 29, 2016, Ann Arbor, Michigan. Robotics: Science and Systems Foundation, 2016: 1608-1616.
- [15] Li B. 3D fully convolutional network for vehicle detection in point cloud[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 24-28, 2017, Vancouver, BC, Canada. New York: IEEE Press, 2017: 1513-1518.
- [16] Yu Z J, He X. Research on intrusion clearance detection system for high-speed railway based on binocular stereo vision[C]//Proceedings of 2011 IEEE International Conference on Service Operations, Logistics and Informatics, July 10-12, 2011, Beijing, China. New York: IEEE Press, 2011: 532-536.
- [17] Ning B, Yu Z J, Zhu L Q, et al. Remote observation system of railway and its application[J]. Journal of the China Railway Society, 2014, 36(12): 62-69.
宁滨, 余祖俊, 朱力强, 等. 铁路远程瞭望系统研究与应用[J]. 铁道学报, 2014, 36(12): 62-69.
- [18] Zhang J L. Automatic track monitoring and alarming system and its application[J]. China Railway, 2019 (3): 95-99.
张景利. 线路障碍自动监测报警系统及其应用[J]. 中国铁路, 2019(3): 95-99.
- [19] Liu Y. Research on improved intrusion monitoring scheme for railways [J]. Railway Signalling & Communication Engineering, 2013, 10(2): 30-32.
刘洋. 一种改进的铁路异物侵限监测方案研究[J]. 铁路通信信号工程技术, 2013, 10(2): 30-32.
- [20] Shi H M, Chai H, Wang Y, et al. Study on railway embedded detection algorithm for railway intrusion based on object recognition and tracking[J]. Journal of the China Railway Society, 2015, 37(7): 58-65.
史红梅, 柴华, 王尧, 等. 基于目标识别与跟踪的嵌

- 入式铁路异物侵限检测算法研究[J]. 铁道学报, 2015, 37(7): 58-65.
- [21] Dong H H, Ge D W, Qin Y, et al. Research on railway invasion detection technology based on intelligent video analysis[J]. China Railway Science, 2010, 31(2): 121-125.
董宏辉, 葛大伟, 秦勇, 等. 基于智能视频分析的铁路入侵检测技术研究[J]. 中国铁道科学, 2010, 31(2): 121-125.
- [22] Zheng Y H, He J Y. Research on obstacle monitoring and alarm system on railway lines[J]. China Railway, 2019(9): 111-117.
郑亚宏, 何家玉. 铁路线路障碍监测报警系统研究[J]. 中国铁路, 2019(9): 111-117.
- [23] 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.
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.
- [24] Su Y T, Bethel J, Hu S W, et al. Octree-based segmentation for terrestrial LiDAR point cloud data in industrial applications[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 113: 59-74.
- [25] Vo A V, Hong L T, Laefer D F, et al. Octree-based region growing for point cloud segmentation[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 104: 88-100.
- [26] Han X F, Jin J S, Wang M J, et al. A review of algorithms for filtering the 3D pointcloud[J]. Signal Processing: Image Communication, 2017, 57: 103-112.
- [27] Schall O, Belyaev A, Seidel H P, et al. Adaptive feature-preserving non-local denoising of static and time-varying range data[J]. Computer-Aided Design, 2008, 40(6): 701-707.