

基于车载激光点云的路面坑槽检测方法

马新江¹, 岳东杰^{1*}, 沈月千¹, 刘如飞², 王旻焯², 俞家勇^{3**}, 张春阳⁴¹河海大学地球科学与工程学院, 江苏 南京 211100;²山东科技大学测绘与空间信息学院, 山东 青岛 266590;³安徽建筑大学土木工程学院, 安徽 合肥 230601;⁴青岛秀山移动测量有限公司, 山东 青岛 266590

摘要 针对基于车载激光点云的坑槽检测受道路横、纵坡度影响而导致误检和漏检等问题,提出了一种联合粗糙度与负偏态分布的路面坑槽检测方法。首先利用垂直度分割路面点云。然后,通过M估计样本一致性(MSAC)拟合局部基准平面,并计算点云的粗糙度;以粗糙度较小的区域作为潜在坑槽区域,并利用密度聚类 and 连续度实现潜在坑槽的单体化。最后,根据坑槽与邻域路面点云的粗糙度统计特征,结合负偏态分布实现坑槽区域的精确筛选,并提取坑槽的三维几何特征。采用开源数据和实测数据进行实验验证与分析。实验结果表明:实测数据路面中,坑槽检测的召回率达到89.2%,准确率达到76.7%;坑槽几何特征的提取结果与人工实地测量结果的最大相对偏差为9.4%,可为大规模的路面损坏检测提供有力支撑。

关键词 遥感; 车载激光点云; 粗糙度; 偏态分布; 路面坑槽检测

中图分类号 P237; U418

文献标志码 A

DOI: 10.3788/CJL231000

1 引言

道路作为交通运输的重要载体,对推动交通强国发展具有重要的作用^[1]。但是,经过连续长时间自然环境和车辆载荷的作用,路面会逐渐产生裂缝、坑槽和车辙等多种类型和不同程度的损坏。其中,坑槽是道路功能性损坏,严重影响车辆的稳定性、驾驶人的安全性和舒适度,以及道路的美观性和使用年限。准确、及时地检测坑槽,对日常行车安全、评估路面损坏程度和制定科学合理的养护计划具有至关重要的意义。

传统路面坑槽检测采用人工巡检方法,存在工作人员的安全性无法充分保障、巡检速度较慢和成本较高以及现场记录的位置不精确等不足。安全性更高的智能化巡检研究主要集中在震动异常检测、二维图像处理、三维立体检测等。震动异常检测通过测距仪等传感器信号的异常变化检测坑槽的位置^[2-4]。该方法虽然成本较低、数据处理速度较快,但漏检的情况较为严重,且无法获取坑槽的尺寸和面积等信息。基于二维图像的坑槽检测方法主要有图像增强^[5-7]、形态学处理^[8-9]或深度学习^[10-12]等。然而,图像易受光照、阴影和水渍等影响,可能导致坑槽位置、深度和面积等结果不准确。三维立体检测方法中,线结构光扫描技术利用光条因高差而产生形变的原理^[13],得到坑槽的位置

和几何特征,但目前单次扫描的范围限制在单车道,无法做到多车道或全车道的扫描检测^[14]。三维重建方法利用双目立体视觉^[15-16]或运动恢复结构(SFM)^[17-19]等方法,将路面图像重建为三维点云,检测方法与基于三维激光点云的方法类似;但大规模室外场景的三维重建对图像和算法的要求较高,重建稳定性还有待验证。车载移动激光扫描(MLS)系统可以在不影响正常交通的情况下,长时序、不间断地获取道路场景带有地理空间位置的点云数据,便于立体直观地展示路面损坏在道路中的位置和空间形态,并为路面状况检测和评估提供重要的三维基础数据^[20]。

目前,通过车载激光点云检测坑槽的方法主要分为逐线检测和基于面的检测。基于线的检测方法利用降维的思想获取扫描线或剖面线,通过局部线拟合和高程异常检测获取坑槽点^[21-23]。该方法相对直观易懂,但对单线上的噪点较为敏感。基于面的检测方法通过拟合局部面来计算点到面的相对距离,用于筛选坑槽区域^[24-27]。该方法综合考虑了坑槽的整体三维特征和局部聚集特征,较为立体、直观,可解释性强,其核心在于基准面的获取方式和范围,以及有向距离的计算。但受道路环境复杂和横、纵向坡度的影响,不准确的局部面模型和相对距离是导致坑槽被错误提取或漏提取的重要原因;且已有的研究还未对局部面拟合

收稿日期: 2023-07-07; 修回日期: 2023-08-01; 录用日期: 2023-08-11; 网络首发日期: 2023-08-15

基金项目: 国家自然科学基金(41801379, 42001414, 42106180)

通信作者: *yuedongjie@163.com; **yujiayongskd@163.com

的范围进行细致的对比分析和明确的界定。因此,在海量车载移动激光点云中精确识别路面坑槽仍然是一项具有挑战性的工作。

针对利用车载激光点云的坑槽检测受路面坡度干扰而存在误检和漏检等问题,本文对基于面的坑槽检测方法进行优化,提出了一种基于粗糙度和偏态分布的坑槽检测方法。该方法从路面点云分割、潜在坑槽点云分离和坑槽判断等方面入手,利用M估计样本一致性(MSAC)拟合局部基准平面,并通过点云粗糙度筛选潜在坑槽;将坑槽及其邻域路面区域作为整体,利用其负偏态分布的统计特征实现坑槽的准确判断。

2 路面坑槽检测方法

坑槽是路面骨料局部脱落而产生的坑洼^[28],在局

部范围内,坑槽具有明显的凹陷特性,其高度低于其周围正常路面的高度;而且,坑槽具有明显的相对独立性。基于上述特征,本文方法的流程如图1所示,主要包括三个步骤:路面点云分割,坑槽初步分离和统计量化判断。首先,利用布料模拟滤波(CSF)算法获取近地面点,并利用垂直性和层次聚类从复杂的车载激光点云中分割路面点云。然后,基于MSAC方法计算点到局部基准面的相对有向距离(即粗糙度),实现潜在坑槽区域的初步定位和筛选;随后利用基于密度的DBSCAN聚类算法和点云连续性进行潜在坑槽的单体化分割与去噪。最后,对潜在单体坑槽进行邻域扩充,依据粗糙度的分布统计规律和偏态系数实现坑槽的精确判断,并基于坑槽的独立性和区域连通性,计算其深度、投影面积和修补尺寸等几何特征。

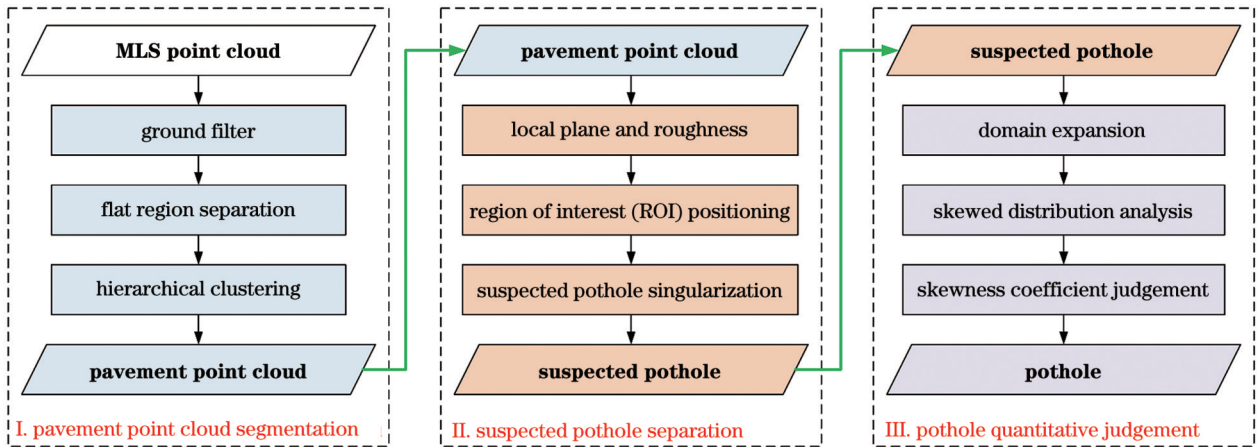


图1 路面坑槽检测算法流程

Fig. 1 Flow of pavement pothole detection algorithm

2.1 路面点云分割

道路场景的MLS点云不仅包含路面和路缘石等道路点云,还包括车辆、树木、灯杆、建筑物和噪声点等大量非行驶区域点云^[29-31]。坑槽是相对于正常路面的低洼,依存于路面之中,因此,完整准确的路面点云是提取坑槽的前提。基于路面的相对平坦性和连续性,以及路缘石或道路隔离墩作为路面边界的分隔性,主要通过垂直度和层次聚类对MLS路面点云进行分割。

首先,通过CSF算法^[32]分割近地面点云,删除高于路面的树木和灯杆等非地面点云。然后,计算近地面点云的法向量 \mathbf{N} ,路面和人行道等平坦区域的法向与 z 轴大致平行,路缘石中间区域的法向与 z 轴有一定的夹角,竖直的灯杆的法向近似垂直于 z 轴。随后利用下式计算点云的垂直度 V ^[33-34]:

$$V = 1 - |\mathbf{N}_z|, \quad (1)$$

式中: \mathbf{N}_z 是法向量 \mathbf{N} 在 z 轴上的分量。

通过阈值筛选,保留路面、人行道和整齐的植被等垂直度较小的平坦区域点云,删除路缘石和车辆轮胎等垂直度较大的区域点云。最后,对平坦区域进行基于欧式距离的层次聚类。作为可行驶区域的路面通常

是最大的连通区域,因此,点数量最大的聚类簇即为路面区域点云。

2.2 基于粗糙度的潜在坑槽分离

如图2所示,本研究中粗糙度的定义如下:以点 p 为中心,利用其邻域范围 r_a 内的点拟合基准平面 S ,点 p 到基准平面 S 的有向垂直距离记为点 p 的粗糙度。平面方程和粗糙度的计算公式分别为

$$A \cdot x + B \cdot y + C \cdot z + D = 0, \quad (2)$$

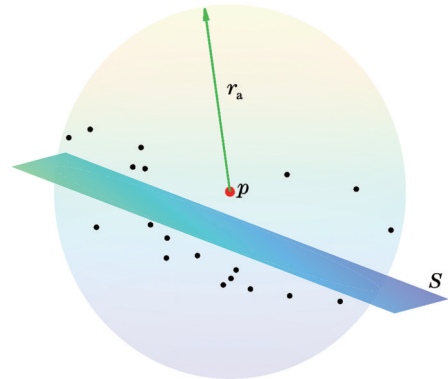


图2 粗糙度示意图

Fig. 2 Diagram of roughness

$$R_p = z_p + \frac{A \cdot x_p + B \cdot y_p + D}{C}, \quad (3)$$

式中: A 、 B 、 C 、 D 是平面模型 S 的参数; R_p 为点 p 的粗糙度; x_p 、 y_p 、 z_p 是点 p 的坐标。

2.2.1 局部基准平面拟合

针对具有凹陷形态的坑槽, 理想的基准平面应贴合坑槽的顶部边缘。但路面环境复杂, 实际的点云数据存在波动, 因此, 在不借助第三方数据的情况下, 可以通过数据拟合获得局部基准平面。相比于利用全局优化策略的最小二乘法, 将坑槽内部点视为内点, 坑槽邻域点视为外点, 运用统计与迭代策略的随机采样一致性 (RANSAC) 算法^[35] 可以较好地获取局部基准平面。RANSAC 是在给定模型和距离阈值 T 的情况下, 通过寻找最小代价 C 来确定内点数据并拟合模型:

$$C = \sum_i^n \rho(e, T), \quad (4)$$

式中: $\rho(e, T)$ 是代价函数; n 是数据总量; i 表示数据的序号。

代价函数为

$$\rho(e, T) = \begin{cases} 1, & e \geq T \\ 0, & e < T \end{cases}. \quad (5)$$

当点到模型的距离 e 小于阈值 T 时, 该点被判定为内点且权重为 0; 否则为外点。由于所有内点的权重为 0, 所以 RANSAC 选取的最优模型是内点最多且权重和最小的模型。如果用于区分异常值的阈值 T 过大, 则会造成 RANSAC 拟合误差增大。

MSAC 是 RANSAC 的一种改进方法^[36], 目的是降低算法对于阈值 T 选取的依赖。修改后的代价函数为

$$\rho(e, T) = \begin{cases} T, & e \geq T \\ e, & e < T \end{cases}. \quad (6)$$

当点到模型的距离 e 小于阈值 T 时, 该点被判定为内点且权重为 e ; 否则为外点且权重为 T 。

由于使用更加精确的距离表达代价函数, 因此, MSAC 不仅可以得到更好的模型, 还可以降低阈值的敏感度以及提高收敛速度。利用 MSAC 进行局部基准面拟合的具体步骤如下。

1) 从数据集中不重复地随机选择用于平面模型拟合的最小数据集 Q 。

2) 利用最小二乘法和数据集 Q 拟合平面模型 S , 得到模型参数。

3) 计算所有点到平面模型 S 的距离, 在允许误差阈值范围内的点标记为“内点”, 并计算该平面模型的代价 C_i 。

4) 比较当前模型的代价 C_i 与之前最好模型的代价 C_b 的大小, 记录较小者作为新的最好模型的代价, 并记录对应的“内点”和模型参数。

5) 重复步骤 1~4, 直到迭代结束, 并得到“内点”数据。

6) 利用“内点”数据, 通过最小二乘法拟合平面模型, 得到最佳的平面模型参数。

2.2.2 潜在坑槽定位

针对坑槽的凹陷形态, 令平面模型的法向量指向 Z 轴正方向, 并计算点到平面的有向垂直距离, 即粗糙度。通过调整法向量的朝向, 使坑槽内部点云的粗糙度统一为负值, 粗糙度越小, 坑槽深度越大。高程渲染和粗糙度渲染的路面点云如图 3 所示。从图 3 可以看出, 受路面坡度影响, 部分坑槽与正常路面的高程可能相同, 导致高程无法显著地区分正常路面和坑槽; 而本文方法计算的粗糙度可以明显地区分正常路面和坑槽, 避免了路面坡度对坑槽的影响。筛选粗糙度小于阈值的点云, 作为潜在坑槽区域。

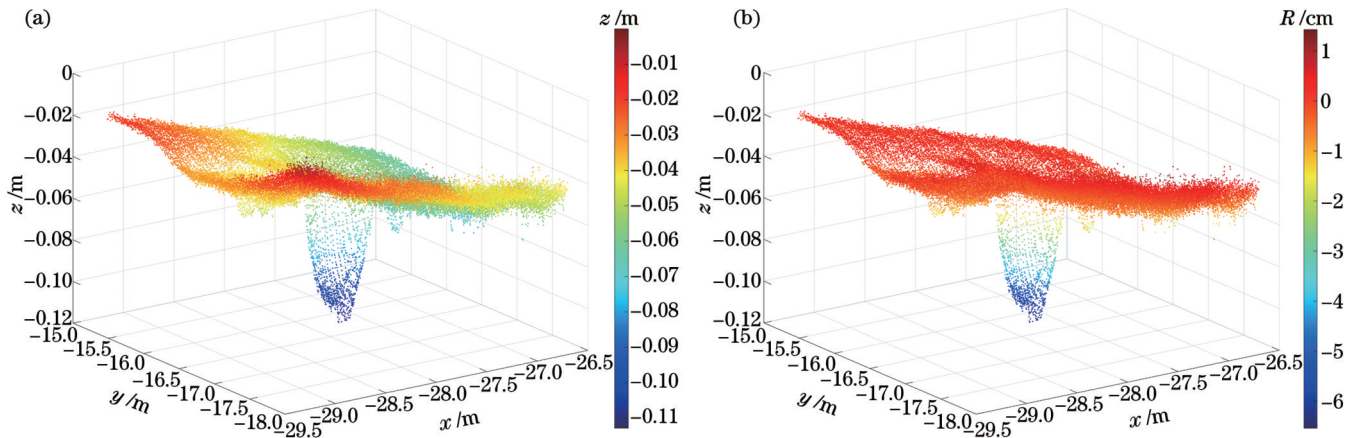


图 3 路面点云。(a) 高程渲染; (b) 粗糙度渲染

Fig. 3 Pavement point clouds. (a) Elevation rendering; (b) roughness rendering

2.2.3 潜在坑槽单体化

受裂缝和路面不平整性的影响, 初步筛选出的潜在坑槽区域不仅存在相对聚集的潜在坑

槽点, 而且存在零星分布的异常点。因此, 基于坑槽内部的凹地聚集效应, 利用 DBSCAN 将潜在坑槽区域划分为不同的聚类簇。通过点数量

限制,将零星的点删除,保留相对集中的聚类簇。

车载激光点云按照返回顺序连续排列,相邻两个点的序号理论差值为 1。若存在缺失的点,则点云序号不连续。本文定义点云的连续度如下:单条扫描线上,所有点按照返回顺序号从小到大排序,实际点数量与理论点数据量的比值记为连续度 C_{co} ,计算公式如下:

$$C_{co} = \frac{n}{I_E - I_S + 1}, \quad (7)$$

式中: n 为实际点数量; I_S 为首点序号; I_E 为末点序号; $I_E - I_S + 1$ 代表理论上的点数量。

坑槽内部点云是连续的;而部分类似坑槽且有高差起伏的路面损坏,如沉陷、松散、龟裂等,内部点云存在不连续性。因此,计算聚类簇中每条扫描线的点云连续度,保留平均连续度大于 0.9 的聚类簇,即为单体化的潜在坑槽。

2.3 基于负偏态分布的坑槽量化判断

2.3.1 潜在坑槽区域外扩

坑槽依存于路面之中,是相对于正常路面的低洼。在没有路面点云对照时,由 2.2 节提取的潜在坑槽点云,还无法直接准确地判定真正的坑槽。因此,通过邻域扩展,将潜在坑槽区域及其邻域路面区域作为一个整体去判断。针对不同形状和不同大小的潜在坑槽,利用其自身的尺度自适应地计算外扩半径 r_e ,计算方法为

$$r_e = \frac{\min(L, W)}{2}, \quad (8)$$

式中: L 和 W 分别为潜在坑槽在 xoy 平面上的最小外接矩形(MBR)的长度和宽度。

以潜在坑槽点为种子点,以外扩半径 r_e 作为欧式聚类的阈值,通过球形邻域的区域生长,获得其周围的

点,记为潜在坑槽的邻域点。如图 4 所示,黑色实心小点为路面点,红色星号点为种子点,绿色圆圈点为邻域点,蓝色箭头为外扩半径。

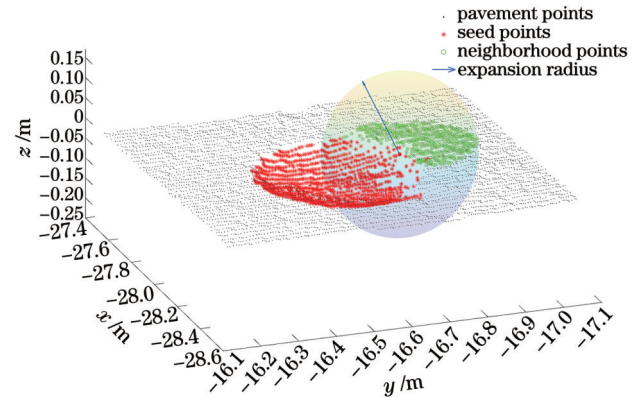


图 4 坑槽区域外扩示意图

Fig. 4 Diagram of pothole zone expansion

2.3.2 偏态系数判断

偏态分布是相对于正态分布而言的,即分布曲线左右不对称的数据分布,分为正偏态和负偏态两种。如图 5(a)所示,正偏态分布的曲线右侧偏长,左侧偏短,均值 \bar{x} 、中值 x_{me} 、众数 x_{mo} 的关系为: $x_{mo} < x_{me} < \bar{x}$;如图 5(b)所示,负偏态分布的曲线左侧偏长,右侧偏短,均值 \bar{x} 、中值 x_{me} 、众数 x_{mo} 的关系为: $\bar{x} < x_{me} < x_{mo}$ 。偏态系数是对数据分布偏倚程度进行规范度量的专门测度,用 S_{sk} 表示,一般为三阶中心距与标准差三次方的比值。其中,正偏态分布的偏态系数为正值,负偏态分布的偏态系数为负值。偏态系数的计算公式为

$$S_{sk} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n \cdot \sigma^3}, \quad (9)$$

式中: n 为数据量; x_i 为第 i 个数据; \bar{x} 为数据的均值; σ 为数据的标准差。




图 5 偏态分布示意图。(a)正偏态分布;(b)负偏态分布

Fig. 5 Diagram of skewed distribution. (a) Positive skewed distribution; (b) negative skewed distribution

局部区域内,正常路面点云的粗糙度呈正态分布。坑槽点云是相对于正常路面点云的异常数据,坑槽及其邻域路面区域点云的粗糙度呈负偏态分布,偏态系数为负值。图 6 是粗糙度渲染的坑槽及其

邻域路面点云(俯视图),圆圈 A 和 C 区域是坑槽周围的正常路面,圆圈 B 区域是邻域外扩后的坑槽区域;三个区域位于同一段路面,相邻且点数量相当。三个区域分别对应图 7 的局部放大图和图 8 的粗糙




图 6 粗糙度渲染的坑槽及其邻域路面点云(俯视图)

Fig. 6 Pothole and its neighboring pavement point clouds rendered by roughness (top view)

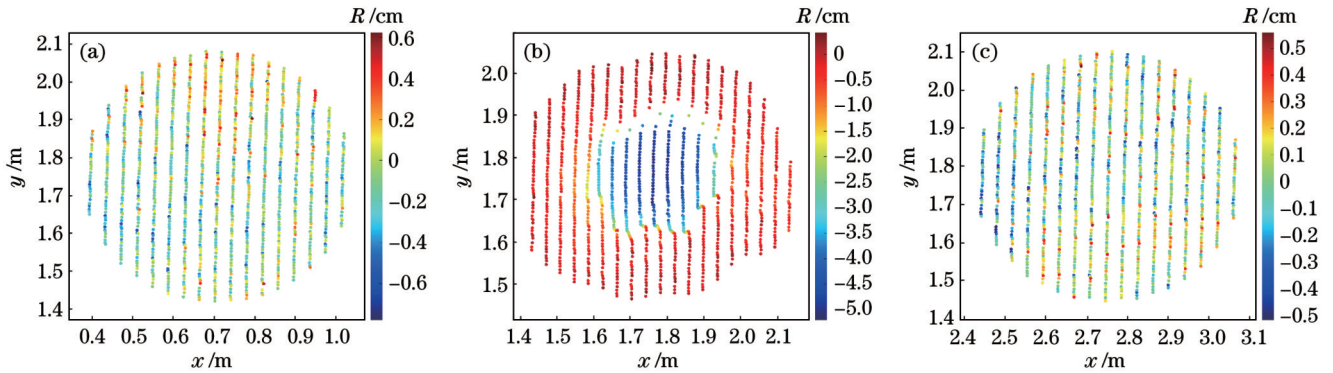


图 7 局部放大图。(a)区域A;(b)区域B;(c)区域C

Fig. 7 Partially enlarged view. (a) Zone A; (b) zone B; (c) zone C




图 8 粗糙度统计直方图。(a)区域A;(b)区域B;(c)区域C

Fig. 8 Histograms of roughness. (a) Zone A; (b) zone B; (c) zone C

度统计分布图。因此,通过计算偏态系数,可以实现坑槽的量化判断。如果粗糙度直方图的均值、中值和众数符合负偏态分布规律,且偏态系数在预设的阈值范围内,则判定该区域为坑槽区域,进而提取其三维几何特征。

2.4 坑槽三维几何特征提取

本文提取的坑槽三维几何特征包括深度、投影面积、沿车道线方向的长度和宽度等。

坑槽深度是坑槽最深处与其周围正常路面的最大高程差。因此,以坑槽内部点云的粗糙度绝对值的最大值作为坑槽深度。

坑槽投影面积表示坑槽区域在水平面上投影的面积。首先将坑槽点投影到 xoy 平面上;然后采用 Alpha-Shapes 从坑槽点中提取其边界点,并连接成闭合线;最后计算其边界轮廓所围成的面积,即坑槽的投影面积。

依照“圆坑方补,斜坑方补”^[37]的修补原则,计算坑槽沿车道线方向的长度和宽度。首先构建局部坐标系:车道线行驶方向为 x 轴,垂直于车道线方向为 y 轴;然后计算坑槽点云在局部坐标系下的尺寸,作为其长度和宽度。

3 实验结果与分析

3.1 实验环境与参数设置

3.1.1 实验环境

为了验证本文方法的有效性和准确性,选取开源车载激光点云数据集 iQmulus^[38]的 Z0 区域(以下简称开源数据路面)和山东省青岛市实测的城市道路(以

下简称为实测数据路面)分别进行实验。

开源数据路面采集于法国巴黎的城市道路,图 9 是高程渲染的开源数据点云,该区域的道路长度约 0.3 km,两侧存在大量的汽车和建筑物;点云格式为 PLY,数据量约 428 MB,约 1365 万个点;路面区域的点云线间距为 3~7 cm,单线上点间距为 1~3 cm。




图 9 高程渲染的开源数据点云

Fig. 9 Open source data point clouds rendered by elevation

实测数据路面为长度约 1.6 km 的沥青路面,存在道路中央水泥隔离墩,车流量较大,货车较多;经过多年的使用和自然环境的作用,路面状况差,存在较多裂缝、坑槽和修补等路面损坏。实测数据采集所用的车载激光移动测量系统如图 10 所示,该系统集成了全球导航卫星系统(GNSS)接收机、惯性测量单元(IMU)、全景相机、工业相机和激光扫描仪等传感器;扫描仪的

线频率最高为 200 Hz,测距分辨率为 0.1 mm,角度分辨率为 0.0088°,每秒可采集超过 100 万点;数据采集时的车速约为 30 km/h。如图 11 所示,扫描范围内包括路面、路缘石、绿化带、行道树、交通附属设施和车辆等;点云格式为 LAS,数据量约 5.2 GB,约 1.65 亿个点;路面区域的点云线间距为 3~5 cm,单线上点间距为 0.3~5 cm。



图 10 车载激光移动测量系统

Fig. 10 Vehicle-borne laser mobile measurement system

基于 C++、QT、LAStools、点云库(PCL)和 Visual Studio 集成开发环境进行编程,在笔记本电脑上进行实验。笔记本电脑为 Windows 11(64 位)操作

系统,CPU 型号为 Intel(R) Core(TM) i7-12700H,主频为 2.3 GHz, RAM 为 32 GB, GPU 型号为 NVIDIA GeForce RTX 3060 Laptop。




图 11 高程渲染的实测数据点云

Fig. 11 Actually measured data point clouds rendered by elevation

3.1.2 参数设置

本文方法的关键参数如表 1 所示。

表 1 本文方法的主要参数
Table 1 Key parameters of proposed method

Notation	r_s	V	r_a	R	S_{SK}
Value	0.1 m	0.1	0.5 m	-1.5 cm	0

球形邻域半径 r_s 用于获取局部范围内点云,并计算法向量,选取依据为路缘石的高度。该阈值可设置为路缘石高度的 0.5~2 倍,与路缘石高度相同为最佳;否则,路缘石的垂直特征和作为路面边界的分隔特征将被周围的路面点影响。城市道路的路缘石高度一般

为 0.1~0.2 m,本文设置 r_s 为 0.1 m。

垂直度阈值 V 用于筛选平坦区域,选取依据为路面和路缘石特征。路面区域的垂直度较小,接近于 0;路面两侧边缘为路缘石或道路隔离墩,垂直度较大,接近于 1;植被等地物的垂直度介于 0~1 之间。因此,为了保留路面和坑槽点云,同时删除路缘石点云、轮胎与路面相交处的点云、建筑物点云和植被点云等,本文设置 V 为 0.1。

邻域范围 r_a 用于计算粗糙度,选取依据为坑槽的相对独立性和凹地聚集特征。随着观测尺度的变化,坑槽区域的边缘突变特征、内部特征和三维整体空间特征也会发生变化。图 12 是不同邻域范围的粗糙度

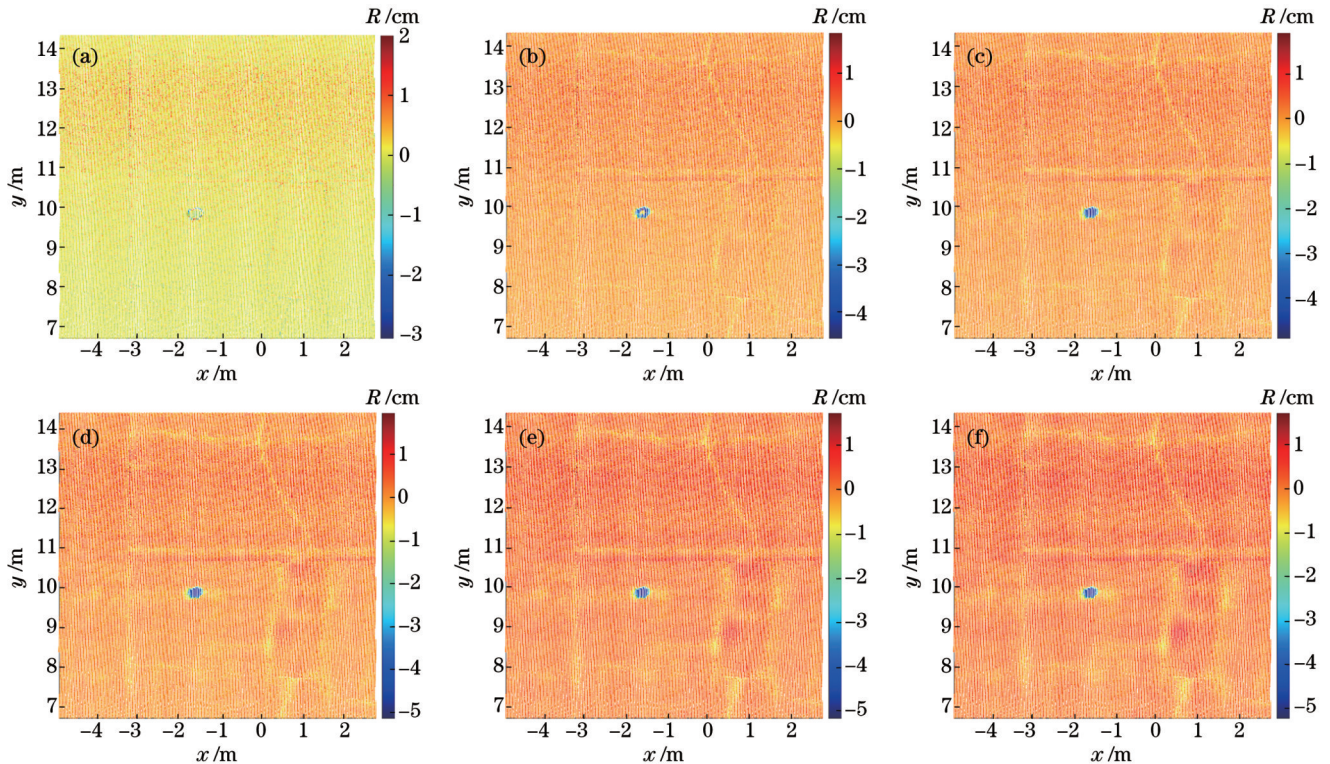


图 12 粗糙度随邻域范围的变化。(a) $r_a=0.1$ m; (b) $r_a=0.2$ m; (c) $r_a=0.3$ m; (d) $r_a=0.4$ m; (e) $r_a=0.5$ m; (f) $r_a=0.6$ m

Fig. 12 Roughness under different neighborhood range. (a) $r_a=0.1$ m; (b) $r_a=0.2$ m; (c) $r_a=0.3$ m; (d) $r_a=0.4$ m; (e) $r_a=0.5$ m; (f) $r_a=0.6$ m

渲染图。图 13 是坑槽边缘点、内部点和正常路面点的粗糙度变化图。从图 12 和图 13 可以看出,在较小的观测尺度下,坑槽的边缘特征较为明显,三维整体空间特征较弱。随着观测尺度的增加,三维整体空间

特征逐渐增强,粗糙度逐渐降低,最终趋于稳定,与正常路面区分较为明显。 r_a 为 0.5 m 时,坑槽区域的粗糙度开始趋于稳定,坑槽和正常路面已经可以明显区分。




图 13 坑槽边缘点、内部点和正常路面点的粗糙度变化

Fig. 13 Roughness variation of pothole edge point, pothole internal point and pavement point

粗糙度阈值 R 用于筛选潜在坑槽点,选取依据为标准规范和点云精度。结合现行的《公路技术状况评定标准》(JTG 5210—2018)^[39]中对坑槽等损坏的判断标准,该阈值应该小于 -1.0 cm。同时考虑到局部范围内点云厚度问题,对路面数据进行局部采样和平面拟合,平面拟合中误差为 $0.2\sim 0.5$ cm。因此,设置该阈值为 -1.5 cm,避免沉陷和车辙等损坏的影响,防止出现大面积的潜在坑槽点。

偏态系数 S_{sk} 用于坑槽区域的量化判断,选取依据为坑槽区域的粗糙度统计特征。坑槽与其周围路面点云的粗糙度直方图呈负偏态分布,对应的偏态系数小于 0,因此设置该阈值为 0。

3.2 路面坑槽检测结果的初步分析

利用本文方法首先对实验数据进行路面点云分割。利用 CSF 算法进行地面滤波时,考虑到道路坡度的不确定性,为了保证路面的完整性,设置布料硬度为 1;提取路面的过程需要路缘石作为边界,因此高度阈值需要大于路缘石高度,设置为 2 m;其他参数如迭代次数设置为 500,布料分辨率设置为 2 m。之后利用垂直度和层次聚类分割路面点云。路面点云如图 14 中蓝色区域所示。

然后,利用本文方法从路面点云中检测坑槽。利用 DBSCAN 进行单体化时,考虑到点云线间距和单线上的点间距,同时为了防止坑槽被分割为多个聚类簇,针对开源数据的邻域半径设置为 0.1 m,针对实测数据的邻域半径设置为 0.05 m;为了防止局部零星噪点,设置聚类簇最小点数量为 20。随后通过邻域外扩和计算粗糙度直方图的偏态系数,进行坑槽的量化判断。

图 15 为开源数据路面的坑槽检测结果,白色底




图 14 路面点云和地面点云的叠加显示图。(a) 开源数据;(b) 实测数据

Fig. 14 Superimposed display of road point cloud and ground point cloud. (a) Open source data; (b) measured data

图为路面点云,黄色或红色点云为检测到的坑槽。图 16 为图 15 方形虚线框中的采用粗糙度渲染的部分坑槽区域放大图。结合粗糙度渲染的路面点云,我们发现该路段的路面状况较差,存在较多的裂缝、坑槽和沉陷等损坏。从检测结果可以看到,本文方法可以




图 15 开源数据路面的坑槽检测结果。(a)整体结果;(b)区域 I 的检测结果;(c)区域 II 的检测结果

Fig. 15 Pothole detection results for open source data pavement. (a) Overall results; (b) detection results of region I; (c) detection results of region II

检测出多个坑槽,且坑槽的形状多样,表明本文方法受坑槽形状的影响较小。区域 I 和区域 II 附近的路面

损坏较为严重,存在较多的坑槽。区域 II 中的 F 可能是损坏严重的大裂缝或水毁冲沟,虽然不是坑槽,但其存在与坑槽类似的凹陷和高程变化特征,本文方法也可以检测出来,侧面反映了本文方法的适用范围较广。

图 17 为实测数据路面的坑槽检测结果,白色底图为路面点云,黄色或红色点云为检测到的坑槽;虚线框区域的底图是真彩点云,彩色区域为车道边缘处的裂缝形成的沟槽,利用粗糙度渲染。图 18 为图 17 中箭头指向坑槽的全景图和俯视图,坑槽俯视图以粗糙度渲染。通过实验结果可以看出,所提出方法在路面坑槽检测方面表现良好。本文方法可以同时检测多个车道的坑槽,例如结果 A 位于两车道的交界处,结果 B 和结果 D 属于同一方向的不同车道,避免了传统单车道扫描系统无法获取完整坑槽的情况,同时避免了多个车道需要多次扫描作业的情况,在一定程度上节约了外业数据采集的时间,有助于提高整个检测流程的作业效率。同时,检测结果表明本文方法可以检测形状相对规则的坑槽,例如区域 A 和区域 F 的坑槽,它们的三维整体形状与碗类似,周围的路面较为平坦;也可以检测形状不规则的坑槽,如区域 B、C、E 的坑槽,它们的形状不规则,周围路面点的高程也会有一定的差别。

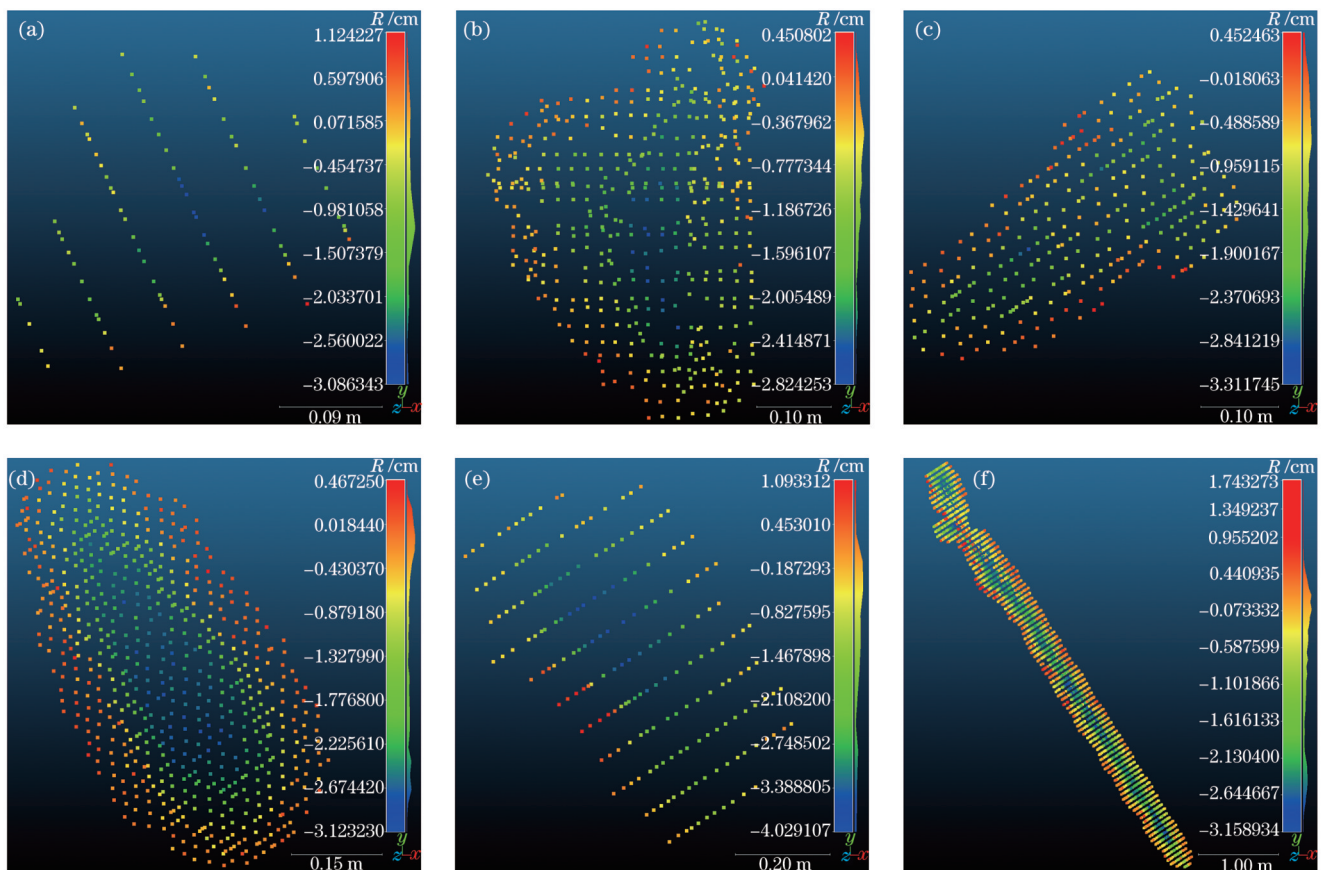


图 16 开源数据路面中检测结果的局部放大图。(a)结果 A;(b)结果 B;(c)结果 C;(d)结果 D;(e)结果 E;(f)结果 F

Fig. 16 Partially enlarged views of detection results in open source data pavement. (a) Result A; (b) result B; (c) result C; (d) result D; (e) result E; (f) result F




图 17 实测数据路面的坑槽检测结果

Fig. 17 Pothole detection results for measured data pavement

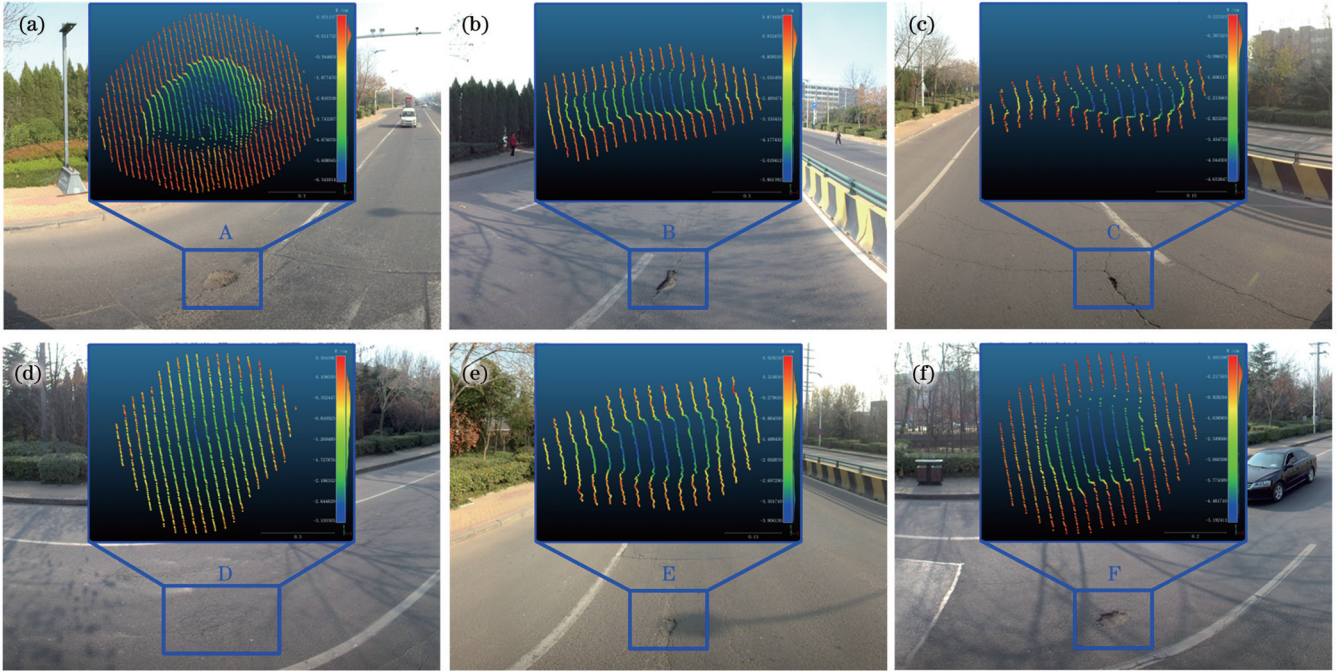


图 18 实测数据路面中检测结果的全景和局部放大图。(a)结果 A;(b)结果 B;(c)结果 C;(d)结果 D;(e)结果 E;(f)结果 F

Fig. 18 Panoramic and partially enlarged views of detection results in measured data pavement. (a) Result A; (b) result B; (c) result C; (d) result D; (e) result E; (f) result F

另一方面,路面沉陷是路基的竖向变形出现的路面下沉,其三维形状与坑槽类似。虽然本文通过点云连续度区分沉陷和坑槽,但部分沉陷较深且面积较大,导致被错误地检测为坑槽,如图 17 虚线框中左下区域的井盖和结果 D。此外,路面最外侧车道边缘和水泥地面交界处存在高差和啃边,导致部分区域呈现为条形的凹槽,如图 17 中虚线框位置,其形状也与坑槽类似,导致错误的检测结果。

3.3 方法的有效性和准确性评价

为了验证本文方法的有效性和准确性,首先选取了文献[26]提出的坑槽检测方法进行对比分析。然后,我们对实测数据路面进行了实地巡检,结合全景影像数据记录坑槽的位置。在保证人员安全的情况下,选取靠近道路两侧的 8 个坑槽,测量其深度、沿车道行驶方向的长度和宽度。

3.3.1 方法的有效性评价

为了定量评价本文方法的坑槽检测效果,选用召

回率和准确率对实测数据路面的检测结果进行评价。召回率 r 和准确率 p 的定义分别为

$$r = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (10)$$

$$p = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (11)$$

式中: N_{TP} 表示正确检测到的坑槽数量; N_{FN} 表示漏检测的坑槽数量; N_{FP} 表示误检测为坑槽的数量。

文献[26]方法的关键参数为分块边长和深度阈值,考虑到路面坡度和点云质量,分块边长设置为 0.5 m,深度阈值设置为 -1.5 cm。两种方法检测结果的量化指标数据如表 2 所示。在实测数据路面中,文献[26]方法检测到正确的坑槽 27 处,未检测到 10 处,召回率仅为 73.0%,低于本文方法的召回率。其中未检测到的 10 处坑槽包括: 5 处路面坡度相对较大位置的坑槽; 2 处裂缝相交处的空隙形成的轻度坑槽; 2 处修补之后产生下陷而导致的轻度坑槽,与沉陷极其相似; 1 处路面边缘处的坑槽。该方法的准确率仅为 65.9%,检测

到错误的坑槽 14 处,其中包括:8 处车道边缘的条形凹槽;5 处局部凹陷;1 处井盖边缘的下沉。

相比较而言,本文方法检测到正确的坑槽 33 处,未检测到 4 处,召回率达到 89.2%。未检测到的 4 处坑槽包括:3 处裂缝相交处的空隙形成的轻度坑槽;1 处修补之后产生下陷而导致的轻度坑槽,与沉陷极其相似。准确率达到 76.7%,检测到错误的坑槽 10 处,其中包括:3 处重度沉陷,例如图 18(d);5 处车道边缘的条形凹槽;2 处井盖区域的下沉,例如图 17 虚线框中区域。总体而言,本文方法避免了局部分块导致相对距离不准确的情况,并通过统计特征进一步提高了对坑槽的判断能力;而且,在复杂环境和复杂路况下,本文方法可以检测到多个车道不同形状的坑槽,具有一定的适用性和鲁棒性。

3.3.2 方法的准确性评价

为了定量评价本文方法提取坑槽三维几何特征的准确性,将人工实地巡检结果和本文方法的提取结果

表 2 坑槽检测结果

Table 2 Results of pothole detection

Method	N_{TP}	N_{FN}	N_{FP}	$r/\%$	$p/\%$
Method of Ref. [26]	27	10	14	73.0	65.9
Proposed method	33	4	10	89.2	76.7

进行对比。具体对比数据如表 3 所示,其中 AD 为绝对偏差, RD 为相对偏差。图 19 显示了不同几何特征的相对偏差结果。假设以人工测量的结果为真值,通过对比分析可以发现,本文方法从点云中提取的坑槽深度整体略小于人工测量的深度。可能有多个方面的原因:1)坑槽内部存在的沙石等杂物或者点密度的影响,导致坑槽最深位置没有点云;2)受点云精度或局部基准平面的影响,导致粗糙度略小。此外,绝大部分坑槽的长宽绝对偏差在 3 cm 以内,相对偏差在 10% 以内,最大相对偏差为 9.4%,原因可能是受到点云密度或 MLS 点云系统误差的影响。

表 3 坑槽的几何特征对比

Table 3 Comparison of geometric features of potholes

Geometric features		Pothole 1	Pothole 2	Pothole 3	Pothole 4	Pothole 5	Pothole 6	Pothole 7	Pothole 8
Depth	Ours /cm	3.08	5.11	4.42	3.31	4.18	4.35	5.06	6.71
	Manual /cm	3.17	5.25	4.58	3.48	4.36	4.45	5.37	6.86
	AD /cm	-0.09	-0.14	-0.16	-0.17	-0.18	-0.10	-0.31	-0.15
	RD /%	-2.8	-2.7	-3.5	-4.9	-4.1	-2.2	-5.8	-2.2
Projected area	Ours /cm ²	711.54	1012.49	780.18	236.05	445.33	213.74	401.26	1668.75
Length (along lane line)	Ours /cm	26.11	68.94	34.45	20.02	38.26	12.86	22.15	55.63
	Manual /cm	27.25	64.08	33.31	21.65	35.87	11.80	20.98	53.50
	AD /cm	-1.14	4.86	1.14	-1.63	2.39	1.06	1.17	2.13
	RD /%	-4.2	7.6	3.4	-7.5	6.7	9.0	5.6	4.0
Width (perpendicular to lane line)	Ours /cm	37.36	20.05	30.02	16.55	18.66	28.82	25.12	40.21
	Manual /cm	39.21	18.91	30.47	15.34	19.40	26.35	23.03	38.86
	AD /cm	-1.85	1.14	-0.45	1.21	-0.74	2.47	2.09	1.35
	RD /%	-4.7	6.0	-1.5	7.9	-3.8	9.4	9.1	3.5

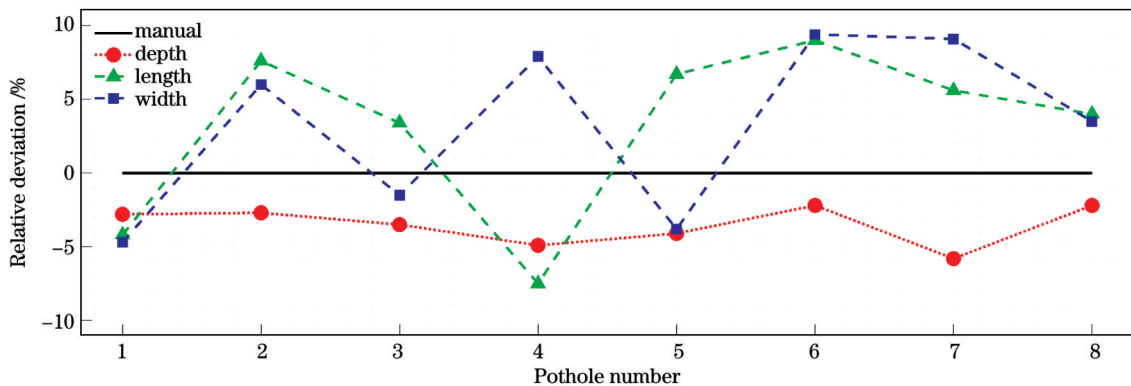


图 19 几何特征对比

Fig. 19 Comparison of geometric features

从以上实验结果可知,本文方法可以从不同点云数据源和不同道路中检测出坑槽。对部分路段的坑槽进行了几何特征提取,验证了实验路段路况较差的真实情况,证明了所提出方法的有效性和实用性。

4 结 论

针对基于车载激光点云的坑槽检测受路面坡度影响严重和局部面模型不准确等问题,本文提出了一种联合粗糙度与负偏态分布的路面坑槽检测方法。首先利用 CSF 方法从车载激光点云中分离地面点云;根据路缘石或道路隔离墩与路面的空间分布差异,利用垂直度和层次聚类从地面点云中提取路面点云。然后,为得到准确的局部基准面和相对距离,利用 MSAC 拟合局部面模型并计算粗糙度;针对潜在坑槽区域存在噪点的问题,依据坑槽的凹地聚集性,利用密度聚类和点云连续度实现潜在坑槽区域的去噪与单体化。为实现坑槽的准确判断,将潜在坑槽和邻域路面点云作为整体进行粗糙度的统计特征分析,利用负偏态分布的统计特征和负偏态系数实现坑槽的准确判断。最后从 MLS 点云中自动提取坑槽的深度、长度和宽度等三维几何特征。为验证本文方法的有效性和准确性,选用开源数据和实测数据分别进行了实验验证与分析。结果表明,本文方法能在大规模复杂道路场景下有效地检测路面坑槽;实测数据中,坑槽检测的召回率和准确率分别达到 89.2% 和 76.7%;三维几何特征的提取结果与人工实地测量结果的最大相对偏差为 9.4%。本文方法为路面损坏信息提取提供了技术参考,有助于道路损坏的准确检测和路况的准确评价。然而,对于损坏程度严重的沉陷,本文方法的鲁棒性还有待提高。后续将进一步研究坑槽和沉陷的不同特征,提高车载点云中坑槽检测的鲁棒性和准确性。

参 考 文 献

- [1] 徐鹏, 祝轩, 姚丁, 等. 沥青路面养护智能检测与决策综述[J]. 中南大学学报(自然科学版), 2021, 52(7): 2099-2117.
Xu P, Zhu X, Yao D, et al. Review on intelligent detection and decision-making of asphalt pavement maintenance[J]. Journal of Central South University (Science and Technology), 2021, 52(7): 2099-2117.
- [2] Eriksson J, Girod L, Hull B, et al. The pothole patrol: using a mobile sensor network for road surface monitoring[C] // Proceedings of the 6th International Conference on Mobile Systems, Applications, and Services, June 17-20, 2008, Breckenridge, CO, USA. New York: ACM Press, 2008: 29-39.
- [3] Mednis A, Strazdins G, Zviedris R, et al. Real time pothole detection using Android smartphones with accelerometers[C] // 2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS), June 27-29, 2011, Barcelona, Spain. New York: IEEE Press, 2011.
- [4] Madli R, Hebbar S, Pattar P, et al. Automatic detection and notification of potholes and humps on roads to aid drivers[J]. IEEE Sensors Journal, 2015, 15(8): 4313-4318.
- [5] 唐磊, 赵春霞, 王鸿南, 等. 路面图像增强的多偏微分方程融合法[J]. 中国图象图形学报, 2008, 13(9): 1661-1666.
Tang L, Zhao C X, Wang H N, et al. Fusion of multiple basic PDE models for enhancing road surface images[J]. Journal of Image and Graphics, 2008, 13(9): 1661-1666.
- [6] 沈瑜, 党建武, 王阳萍, 等. 基于 NSCT 域压缩感知模型的路面病害图像滤波算法[J]. 光电子·激光, 2014, 25(8): 1620-1626.
Shen Y, Dang J W, Wang Y P, et al. A compressed sensing pavement distress image filtering algorithm based on NSCT domain [J]. Journal of Optoelectronics·Laser, 2014, 25(8): 1620-1626.
- [7] Xu Z G, Che Y L, Min H G, et al. Initial classification algorithm for pavement distress images using features fusion[M] // de Pietro G, Gallo L, Howlett R J, et al. Intelligent interactive multimedia systems and services. Smart innovation, systems and technologies. Cham: Springer, 2019, 98: 418-427.
- [8] Ryu S K, Kim T, Kim Y R. Image-based pothole detection system for ITS service and road management system[J]. Mathematical Problems in Engineering, 2015, 2015: 968361.
- [9] Wu L L, Mokhtari S, Nazef A, et al. Improvement of crack-detection accuracy using a novel crack defragmentation technique in image-based road assessment[J]. Journal of Computing in Civil Engineering, 2016, 30(1): 451.
- [10] 沙爱民, 童峥, 高杰. 基于卷积神经网络的路表病害识别与测量[J]. 中国公路学报, 2018, 31(1): 1-10.
Sha A M, Tong Z, Gao J. Recognition and measurement of pavement disasters based on convolutional neural networks[J]. China Journal of Highway and Transport, 2018, 31(1): 1-10.
- [11] Fan R, Wang H L, Wang Y, et al. Graph attention layer evolves semantic segmentation for road pothole detection: a benchmark and algorithms[J]. IEEE Transactions on Image Processing, 2021, 30: 8144-8154.
- [12] Guan J C, Yang X, Ding L, et al. Automated pixel-level pavement distress detection based on stereo vision and deep learning[J]. Automation in Construction, 2021, 129: 103788.
- [13] 惠冰, 郭牧, 王洲, 等. 基于三维激光技术的路面坑槽多维度指标检测[J]. 同济大学学报(自然科学版), 2018, 46(1): 60-66.
Hui B, Guo M, Wang Z, et al. Multi-dimensional index detection of potholes based on 3D laser technology[J]. Journal of Tongji University (Natural Science), 2018, 46(1): 60-66.
- [14] Li F, Ablat G, Zhou S Q, et al. 2D-wavelet based micro and macro texture analysis for asphalt pavement under snow or ice condition[J]. Journal of Infrastructure Preservation and Resilience, 2021, 2(1): 1-15.
- [15] Fan R, Ozgunalp U, Hosking B, et al. Pothole detection based on disparity transformation and road surface modeling[J]. IEEE Transactions on Image Processing, 2020, 29: 897-908.
- [16] Du Y, Zhou Z F, Wu Q Q, et al. A pothole detection method based on 3D point cloud segmentation[J]. Proceedings of SPIE, 2020, 11519: 1151909.
- [17] Tan Y M, Li Y X. UAV photogrammetry-based 3D road distress detection[J]. ISPRS International Journal of Geo-Information, 2019, 8(9): 409.
- [18] Ahmed A, Ashfaq M, Ulhaq M U, et al. Pothole 3D reconstruction with a novel imaging system and structure from motion techniques[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(5): 4685-4694.
- [19] Biçici S, Zeybek M. An approach for the automated extraction of road surface distress from a UAV-derived point cloud[J]. Automation in Construction, 2021, 122: 103475.
- [20] 许梦兵, 韩友美, 王留召, 等. 基于激光点云的高精度井盖提取和沉降病害检测方法研究[J]. 中国激光, 2021, 48(16): 1604001.
Xu M B, Han Y M, Wang L Z, et al. Research on high-precision manhole cover extraction and settlement disease detection method based on laser point cloud[J]. Chinese Journal of Lasers, 2021, 48(16): 1604001.
- [21] 潘宁, 杜豫川, 岳劲松, 等. 基于点云数据的道路变形类病害自动化检测方法[J]. 同济大学学报(自然科学版), 2022, 50(3): 399-408.
Pan N, Du Y C, Yue J S, et al. Automatic detection method of

- pavement deformation distress based on point cloud data[J]. Journal of Tongji University (Natural Science), 2022, 50(3): 399-408.
- [22] Mizutani T, Yamaguchi T, Kudo T, et al. Quantitative evaluation of peeling and delamination on infrastructure surfaces by laser signal and image processing of 3D point cloud data[J]. Automation in Construction, 2022, 133: 104023.
- [23] 廖飞钦, 马荣贵, 王朵, 等. 基于 RANSAC 的公路路面坑槽提取方法[J]. 计算机系统应用, 2022, 31(5): 230-237.
Liao F Q, Ma R G, Wang D, et al. Road pothole extraction method based on RANSAC[J]. Computer Systems and Applications, 2022, 31(5): 230-237.
- [24] 孙权, 程俊毅, 田绍鸿, 等. 基于无人机 LIDAR 数据多尺度特征的沥青路面病害提取方法[J]. 石河子大学学报(自然科学版), 2019, 37(1): 1-11.
Sun Q, Cheng J Y, Tian S H, et al. Retrieval of asphalt road pavement distress using multi-scale features extracted from unmanned aerial vehicle LIDAR data[J]. Journal of Shihezi University (Natural Science), 2019, 37(1): 1-11.
- [25] de Blasiis M R, Di Benedetto A, Fiani M. Mobile laser scanning data for the evaluation of pavement surface distress[J]. Remote Sensing, 2020, 12(6): 942.
- [26] Ravi R, Habib A, Bullock D. Pothole mapping and patching quantity estimates using LiDAR-based mobile mapping systems[J]. Transportation Research Record, 2020, 2674(9): 124-134.
- [27] 陈鑫龙, 马荣贵, 梁红涛, 等. 基于法向量距离的路面坑槽提取方法[J]. 计算机系统应用, 2022, 31(5): 222-229.
Chen X L, Ma R G, Liang H T, et al. Extraction of pavement potholes based on normal vector distance[J]. Computer Systems and Applications, 2022, 31(5): 222-229.
- [28] 中华人民共和国交通部. 公路工程名词术语: JTJ 002—1987[S]. 北京: 中国标准出版社, 1988.
Ministry of Transport of the People's Republic of China. Standard of technical terms for highway engineering: JTJ 002—1987[S]. Beijing: Standards Press of China, 1988.
- [29] 刘如飞, 卢秀山, 岳国伟, 等. 一种车载激光点云数据中道路自动提取方法[J]. 武汉大学学报(信息科学版), 2017, 42(2): 250-256.
Liu R F, Lu X S, Yue G W, et al. An automatic extraction method of road from vehicle-borne laser scanning point clouds[J]. Geomatics and Information Science of Wuhan University, 2017, 42(2): 250-256.
- [30] 姚连璧, 秦长才, 张邵华, 等. 车载激光点云的道路标线提取及语义关联[J]. 测绘学报, 2020, 49(4): 480-488.
Yao L B, Qin C C, Zhang S H, et al. Road marking extraction and semantic correlation based on vehicle-borne laser point cloud [J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(4): 480-488.
- [31] 李维刚, 樊响, 梅洋, 等. 基于车载激光点云的道路标线提取方法[J]. 中国激光, 2022, 49(7): 0710001.
Li W G, Fan X, Mei Y, et al. Road marking extraction method based on vehicle laser point cloud[J]. Chinese Journal of Lasers, 2022, 49(7): 0710001.
- [32] Zhang W M, Qi J B, Wan P, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation[J]. Remote Sensing, 2016, 8(6): 501.
- [33] Demantké J, Vallet B, Paparoditis N. Streamed vertical rectangle detection in terrestrial laser scans for facade database production[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, 1-3: 99-104.
- [34] Guinard S, Landrieu L. Weakly supervised segmentation-aided classification of urban scenes from 3D lidar point clouds[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2017, XLII-1/W1: 151-157.
- [35] 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.
- [36] Torr P H S, Zisserman A. MLESAC: a new robust estimator with application to estimating image geometry[J]. Computer Vision and Image Understanding, 2000, 78(1): 138-156.
- [37] 中华人民共和国交通运输部. 公路路基路面现场测试规程: JTG 3450—2019[S]. 北京: 人民交通出版社, 2019.
Ministry of Transport of the People's Republic of China. Field test methods of highway subgrade and pavement: JTG 3450—2019[S]. Beijing: China Communications Press, 2019.
- [38] Vallet B, Brédif M, Serna A, et al. TerraMobilita/iQmulus urban point cloud analysis benchmark[J]. Computers & Graphics, 2015, 49: 126-133.
- [39] 中华人民共和国交通运输部. 公路技术状况评定标准: JTG 5210—2018[S]. 北京: 人民交通出版社, 2018.
Ministry of Transport of the People's Republic of China. Highway performance assessment standards: JTG 5210—2018[S]. Beijing: China Communications Press, 2018.

Pavement Pothole Detection Method Based on Vehicle-Borne Laser Point Clouds

Ma Xinjiang¹, Yue Dongjie^{1*}, Shen Yueqian¹, Liu Rufe², Wang Minye², Yu Jiayong^{3**},
Zhang Chunyang⁴

¹School of Earth Sciences and Engineering, Hohai University, Nanjing 211100, Jiangsu, China;

²College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, Shandong, China;

³School of Civil Engineering, Anhui Jianzhu University, Hefei 230601, Anhui, China;

⁴Qingdao Xiushan Mobile Surveying Co., Ltd., Qingdao 266590, Shandong, China

Abstract

Objective Road safety is crucial for public well-being and economic prosperity. Accurate and comprehensive pothole inspection is essential to identify potential safety hazards early and take prompt maintenance measures to ensure public safety. Traditional manual inspection has drawbacks including limited staff safety, slow and expensive processes, etc. Hence, efficient and automated

technologies and methods are urgently needed for pavement pothole inspection. Intelligent inspection research focusing on safety enhancements includes vibration anomaly detection, two-dimensional (2D) image processing, and three-dimensional (3D) stereo detection. However, vibration anomaly detection methods may suffer from leakage, while 2D image-based detection methods are susceptible to environmental factors like light, shadows, and water, leading to inaccurate results. Additionally, in 3D stereo detection methods, line structured light scanning technology is limited to single-lane scanning, while 3D reconstruction methods are more demanding in terms of images and algorithms, showing lower robustness. Existing pothole detection methods from vehicle-borne laser point cloud rely on fitting local line or surface models and using height differences to identify pothole, but accuracy is compromised due to the complexity and slope of the pavement. Inaccurate local models and relative distances are significant factors contributing to the incorrect extraction or omission. To address these challenges, we propose a novel method for detecting pavement potholes from vehicle-borne laser point clouds. The goal is to assist road maintenance departments in inspecting and maintaining pavements more effectively, ultimately enhancing the efficiency of pavement damage extraction.

Methods Addressing the challenges associated with pothole detection using vehicle-borne laser point clouds, which can be influenced by road transverse and longitudinal slopes leading to misdetection and omission, in this paper we propose a novel pothole detection method based on roughness and negative skewed distribution. The method involves three main steps: pavement point cloud segmentation, pothole preliminary separation, and statistical quantitative judgement. To begin with, the cloth simulation filter (CSF) algorithm is used to obtain ground point clouds, followed by the segmentation of pavement point clouds from the complex road scenes through verticality and hierarchical clustering. Subsequently, a local plane model is fitted using the M-estimated sample consistency (MSAC) method to obtain the relative directed distance (i.e., roughness), enabling the localization of potential potholes. Density-based spatial clustering of applications with noise (DBSCAN) and point cloud continuity are then utilized for the singularization and denoising of potential potholes. Next, a neighborhood expansion process is conducted for potential monolithic potholes, and their identification is accurately determined based on the statistical laws of roughness distribution and the skewness coefficients. Geometric features such as depth, projected area, and repair size are computed considering the independence and regional connectivity of the potholes. Finally, experiments are conducted using both open source data and measured data to validate the effectiveness and accuracy of the proposed method.

Results and Discussions Based on the continuity and flatness of the pavement, as well as the vertical characteristics of road curbs and their separation as pavement boundaries, this study firstly acquires the accurate pavement point clouds (Fig. 14). The proposed method can accurately detect potholes in multiple lanes and different shapes in both open source data (Figs. 15 and 16) and measured data (Figs. 17 and 18), which proves the effectiveness of the proposed method. Field inspections of the measured data scene reveal impressive results for pothole detection using the proposed method, with a recall rate of 89.2% and an accuracy rate of 76.7%. Notably, both indicators outperform similar methods by over 10% (Table 2). Additionally, the maximum relative deviation of potholes' 3D geometric features between the proposed method and manual field measurement is 9.4% (Table 3 and Fig. 19), further highlighting the applicability and robustness of the proposed method. The experimental results demonstrate the applicability and robustness of the proposed method, which can avoid the inaccuracy of the relative distance due to local grids (Fig. 3) and further improve the judgement of potholes by statistical features.

Conclusions In this study, a novel method for pavement pothole detection that integrates roughness and negative skewed distribution is proposed. Firstly, the pavement point cloud is extracted from the intricate road environment using the CSF method, along with verticality and hierarchical clustering. Then, MSAC is used to fit the planes in order to obtain accurate local planes and relative distances. For the noise issue, DBSCAN and point cloud continuity are used for denoising and singularization of potential potholes. To achieve accurate judgement of potholes, the potential potholes along with their neighboring pavement point cloud are taken as a whole, and the statistical features of roughness are used for quantitative judgement of potholes. Finally, 3D geometric features such as depth, projected area, length and width of potholes are automatically extracted from the point cloud. Experimental results demonstrate the effectiveness of the proposed method in detecting potholes within large-scale complex road scenes. In the measured data, the recall rate and accuracy rate of pothole detection reach 89.2% and 76.7%, respectively. The maximum relative deviation between extracted 3D geometric features and manually measured field results is only 9.4%. Overall, the proposed method offers a valuable technical reference for extracting pavement damage information, enabling accurate detection of road damage and precise evaluation of road conditions.

Key words remote sensing; vehicle-borne laser point clouds; roughness; skewed distribution; pavement pothole detection