

基于图像与点云融合的公路撒落物检测算法

梁浩林, 蔡怀宇*, 刘博翀, 汪毅, 陈晓冬

天津大学精密仪器与光电子工程学院光电信息技术教育部重点实验室, 天津 300072

摘要 公路撒落物是影响行车安全、造成交通堵塞的重要因素,及时检测并清理公路撒落物十分重要。通过总结分析撒落物的特点,利用点云处理定位精度高和图像处理分类精度高的特点,提出一种基于图像与点云融合的公路撒落物检测算法。所提算法包括路面目标提取、点云与图像信息融合和撒落物目标分类等 3 个步骤。首先,通过激光雷达点云进行道路边缘检测、地面点云滤波和点云聚类,提取路面上的目标点云团簇;然后,将目标点云团簇投影到时间与空间对齐的视觉图像中,获取对应的图像感兴趣区域;最后,使用优化后的 ResNet-50 进行目标分类。所提算法的平均检测精确率为 94.84%,召回率为 91.92%,具有良好的检测效果。

关键词 图像处理;撒落物检测;目标分类;深度学习;激光雷达点云;视觉图像

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP213044

Road Falling Objects Detection Algorithm Based on Image and Point Cloud Fusion

Liang Haolin, Cai Huaiyu*, Liu Bochong, Wang Yi, Chen Xiaodong

Key Laboratory of Photoelectric Information, Ministry of Education, School of Precision Instruments and Optoelectronic Engineering, Tianjin University, Tianjin 300072, China

Abstract Road falling objects are an important factor affecting driving safety and causing traffic jams. It is crucial to promptly detect and clean up road litter. By summarizing and analyzing the characteristics of falling objects, using the characteristics of high positioning accuracy of point cloud processing and high classification accuracy of image processing, a highway falling object detection algorithm based on image and point cloud fusion is proposed. The proposed algorithm includes the following three steps: road object extraction, point cloud and image information fusion, and falling object classification. First, the laser radar point cloud is used to detect the road edge, filter the ground point cloud, and cluster the point cloud to extract the target point cloud clusters on the road; second, the target point cloud cluster is projected into the time and space-aligned visual image to obtain the corresponding image region of interest; finally, the optimized ResNet-50 is used for target classification. The average detection accuracy rate of the proposed algorithm is 94.84%, and the recall rate is 91.92%, which has a good detection effect.

Key words image processing; falling object detection; target classification; deep learning; lidar point cloud; visual image

1 引言

公路是我国的国民经济命脉。20 世纪 80 年代以来,我国公路发展愈发迅猛。与其飞速发展相适应,我国需要更为高效和现代化的公路巡检、养护技术与系统。公路撒落物是干扰正常交通的地面物体,是影响行车安全、造成交通拥堵的重要隐患,因此准确快速地检测撒落物十分重要。当前,国内外外少有关于公路撒落物检测系统与算法的研究。目前,准确率较高的检测方案是通过去除阴影结合背景建模的方法^[1]进行前

景目标提取和车辆行人剔除。但由于需要背景建模,该算法不适用于相机实时运动的场景。最新的检测方法通过改进 Faster R-CNN^[2]来进行几种固定种类垃圾的检测,但由于数据集不足,检测效果受限。因此,如何快速准确地检测公路撒落物仍是本研究领域亟待解决的问题。

撒落物检测本质上属于一种特定条件下的目标检测。在目标检测领域,深度学习网络强大的特征提取能力与图形表征能力使其成为目标检测的主流方式。基于深度学习的目标检测方法可以分为图像目标检测

收稿日期: 2021-11-24; 修回日期: 2021-12-31; 录用日期: 2022-01-28; 网络首发日期: 2022-02-08

基金项目: 天津市交通运输科技发展计划项目(2019003)

通信作者: hycai@tju.edu.cn

方法、点云目标检测方法和多传感器融合的目标检测方法。视觉图像可以获取目标的颜色、形状、纹理等信息,但是成像效果会受到外界光照、天气等的影响;点云信息可以获取目标的反射率、距离、三维形状信息且不受光照影响^[3],但是分辨率较低。由于传感器获取信息方式的差异,图像检测和点云检测在不同任务中的表现各有优劣:在目标定位任务中,点云检测的准确程度高于图像检测;在目标分类任务中,图像检测的准确程度高于点云检测。由于公路撒落物大小、形状不确定,而且没有具体明确的特征,这使得单独使用图像检测或点云检测进行准确定位和分类的难度较大,难以实现对公路撒落物的准确检测。

基于多传感器融合的算法可丰富数据种类,提高系统的数据冗余性和容错性,同时可以利用多传感器在不同检测任务中的优势,提升检测精度。在多传感器融合的方法中,基于激光雷达和相机融合的方法是目前公路目标检测领域中应用最广且效果最好的方法之一。MV3D网络^[4]和AVOD网络^[5]将点云与图像同时作为

网络输入来预测回归3D包围框,用于检测自动驾驶场景中的车辆和行人信息。张双喜^[6]提出的“点云定位+图像检测”算法和Frustum PointNet^[7]使用串行的方法将一方的输出作为另一方的输入,用于检测公路上的障碍物目标。以上2种融合思路均能有效利用多传感器的优势,提高目标检测准确性、降低目标漏检率。

基于激光雷达和相机融合的方法通过扩展数据源,在检测精度方面均有明显优势。但目前的算法和网络结构难以对特征不统一的撒落物实现快速准确分类。本文通过研究激光雷达和相机融合的方法,设计了一种用于公路撒落物检测的算法框架,并验证了算法的可行性。

2 基本原理

所提算法的核心原理是将激光雷达扫描的道路上多种物体的点云团簇映射到图像中,然后通过图像目标分类输出公路撒落物的预测结果。算法流程如图1所示。

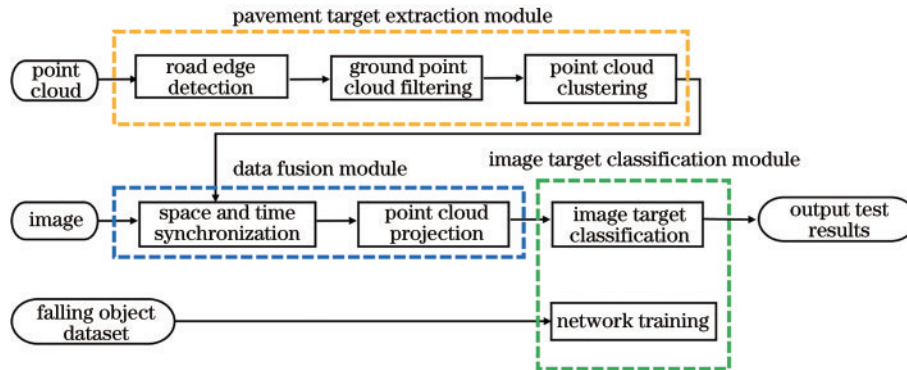


图1 撒落物检测算法流程图

Fig. 1 Flow chart of algorithm for detecting falling objects

该检测算法采用图像与点云融合的方式,分为路面目标提取、点云与图像信息融合、撒落物目标分类等3个步骤。首先,对道路范围内的点云进行分割处理,获取所有路面上物体的点云团簇;然后,对激光雷达与相机进行时间对齐和空间匹配,实现点云团簇到视觉图像的映射,获取图像的感兴趣区域;最后,对获取的图像目标进行分类,获取道路撒落物预测信息,保存图片与对应的位置信息。

2.1 路面目标提取

路面目标提取包括3个步骤:道路边缘检测、地面点云滤波和点云聚类。道路边缘检测用来消除道路外侧点云的干扰,确定检测范围;地面点云滤波用来区分点云中的地面点与地物点,并将地面点剔除;点云聚类对视场中的点云进行分割聚类,便于后期的目标特征提取和分类。

2.1.1 道路边缘检测

在结构化道路中,道路边沿和护栏为道路区和非道路区提供明确的分界线。当单条激光扫描平整的地

面时,输出结果为完整的圆形或扇形。但当激光扫描到边沿或护栏时,扫描线相邻点之间的高度差会发生明显突变,可以根据该特征逐扫描线提取道路边界点。为防止道路两条边界在边缘提取和检测时相互干扰,预先对点云视场中左右2个部分进行分割,并根据车辆运行以及激光雷达扫描情况预设检测范围,道路边缘检测结束后再将左右2个部分进行点云合并。以单条扫描线为例,从检测范围的左边界点向右边界点进行遍历,取每 N 个点为一组计算一次高度差 z ,计算方式为

$$\begin{cases} z_{\min} = \min(z_1, z_2, \dots, z_N) \\ z_{\max} = \max(z_1, z_2, \dots, z_N) \\ z = z_{\max} - z_{\min} \end{cases} \quad (1)$$

当相邻2组之间的高度差 z 出现明显变化时,记录前组的最后一个点为本条扫描线的边界点。得到每条扫描线的边界点后,将所有边界点输入直线拟合算法即可获得道路边缘方程。

由于检测系统中出现明显高度差的原因不仅是道路边缘处的激光扫描,还有车辆抖动等因素。因此,选取随机抽样一致(RANSAC)算法为道路边界拟合提供足够的抗噪能力^[8]。RANSAC算法基于随机采样的原理,选取一组样本子集进行多次迭代,完成边界拟合后获得道路边缘的方程,两条道路边缘线之间的区域即为道路区域。当激光雷达扫描过程中有车辆和人经过时,边界检测会因为短暂的遮挡受到影响。本实验采用限幅滤波算法^[9]来移除错误的检测结果,减小偶然因素引起的误差,保证道路边缘信息提取的准确性。

2.1.2 地面点云滤波

由于地面点的存在会干扰点云聚类,所以需要区分道路区域的地面点与地物点。许多地面点云分割算法容易受到地形特征的影响且需要人工调节参数,鲁棒性差^[10]。Zhang等^[11]提出的布料模拟滤波(CSF)算法可以根据点云数据自动模拟地面形状、自动适应多种地形,鲁棒性强。因此,本实验选择CSF算法进行地面点云滤波。

CSF算法的核心思想如下:首先把待检测的点云上下翻转,然后在翻转后的点云上方放置一块平整的模拟布料,当布料在重力作用下降落到点云上时,最终布料稳定的形状即为模拟地面的形状。因为点云扫描的结果是环境的外轮廓,所以最终的布料会在目标底部或道路崎岖等区域产生不同程度的弯曲,使模拟地面形态更准确。在CSF算法中,首先将布料建模为一个由许多相互连接的质点构成的格网。质点在三维空间中的位置决定布料的位置与形状,该模型为质点弹簧模型。在模型中质点受到内力和外力的影响:外力是重力以及模型遇到障碍物时所产生的碰撞力;内力是相邻节点之间的牵制力。在该模型中粒子会受到周围粒子的牵制作用,牵制力遵循胡克定律。通过计算最终布料格网节点高度与真实点云高度的差值来判断点的归属。差值小于阈值的点为地面点,反之为地物点。根据上述过程即可完成地面点云滤波。

2.1.3 点云聚类

点云聚类的目的是将一组点云数据按照特定的标准分割为不同的点云团簇,使每个团簇中的数据相似性最大。点云聚类可以对整个视场的点云进行分割,便于进行目标特征提取和分类。

所提算法选用基于密度的点云聚类算法,即DBSCAN算法进行点云聚类。通过在数据集中寻找被低密度区域分离的高密度区域,将分离出的高密度区域作为独立的点云簇。通过调节点云的邻域距离阈值和团簇内最少样本个数阈值来控制团簇的大小,同时自动将不属于任何簇的样本数据作为噪声舍弃,避免噪声数据对结果产生的影响。该算法的优势如下:1)既适用于凸样本集,也适用于非凸样本集;2)在检测任意形状点云团簇的同时可以有效过滤噪声点^[12];3)聚类前不需确定目标团簇的具体数量。

2.2 点云和图像信息融合

经过路面目标提取后,可以获得路面上所有物体的点云团簇。但由于撒落物没有统一的特征,因此难以从点云维度将公路撒落物与其他物体分开。而且点云团簇是一些分散的数据点,所包含的目标内容信息不如视觉图像丰富,因此将点云投影到图像中,截取对应的图像感兴趣区域进行撒落物分类。

点云和图像信息融合前需要实现相机和激光雷达的空间对齐和时间对齐。空间对齐是对激光雷达和相机进行联合标定,建立激光雷达坐标系和相机坐标系的转换关系;时间对齐是对激光雷达和相机进行时间戳同步,保证点云和像素的逐帧同步。2种传感器在时间和空间维度对齐后即可获得近似同一时刻下拍摄的图像和点云,再通过激光雷达与相机的坐标系匹配,将聚类完成的点云团簇各数据点的坐标转化为对应的像素坐标。将投影后形成的像素点团簇的最小包围矩形截取出来,即可获得图像感兴趣区域。

2.3 撒落物目标分类

2.3.1 撒落物检测难点分析

公路撒落物是指迟滞或干扰正常交通的地面物体。典型撒落物包括生活垃圾、纸箱货物、黄沙落石等。撒落物检测的难点在于:1)涵盖物体种类多,不同撒落物的大小、颜色、形状、反射率等特性各不相同,特征差距较大;2)天气、光照、路面积水和光斑等环境因素均会影响检测精度;3)出现位置随机,背景信息多变,容易引发漏检和误检等问题;4)撒落物涵盖范围广泛,目前没有公开的数据集。

考虑到撒落物的特征差距大且易受环境影响,采用卷积神经网络(CNN)进行目标分类。

2.3.2 网络模型选择

在几种典型CNN结构中:LeNet^[13]和AlexNet^[14]等网络拟合能力有限,不方便后续研发人员扩展,适用性较差;VGG^[15]网络更容易扩展,且网络拟合效果更好,但随着网络深度增大,检测效果反而变差,会出现网络退化的问题。He等^[16]针对此问题提出ResNet,在类VGG结构的基础上增加残差结构来缓解该问题。残差网络与普通网络的区别在于引入跳跃连接,使上个残差块的信息无阻碍地流入下个残差块中,有效缓解网络过深引起的梯度消失问题和网络退化问题。

在网络深度的选择方面,ResNet有18层、34层、50层、101层和152层这5种不同深度的网络结构。当网络层数到达50后,由于 3×3 卷积的计算量较大,需要将残差结构优化为瓶颈式残差结构。ResNet-50在使用瓶颈式残差结构提高预测准确率的同时,模型复杂度与ResNet-34基本持平。综合考虑网络的分类效果和运算量,本实验采用ResNet-50进行公路撒落物的检测。

2.3.3 网络结构优化

ResNet-50结构如图2所示,网络卷积层与全连接

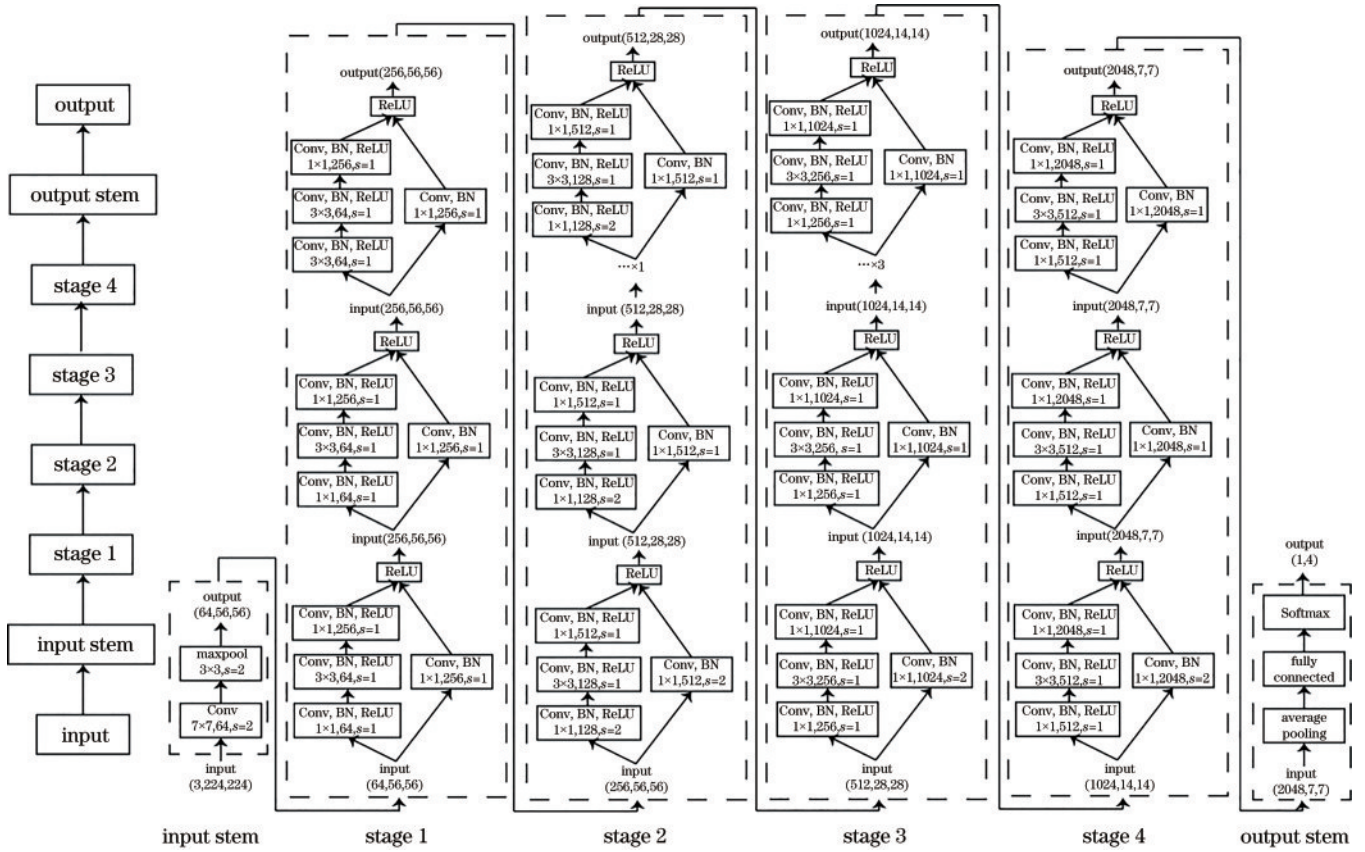


图 2 ResNet-50 结构图

Fig. 2 Structure diagram of ResNet-50

层的总层数为 50 层。输入为 $224 \times 224 \times 3$ 的公路撒落物图片, 经过输入层、stage 1~4 特征采样层、输出层处理即可获得图片与各类物体匹配的概率。输出层通过平均池化与全连接层进一步提取目标特征, 并输入 Softmax 分类器, 最终输出目标属于各类别的概率信息为

$$a^i = \frac{\exp(z^i)}{\sum_{i=1}^4 \exp(z^i)}, \quad (2)$$

式中: 输出值 z^i 表示物体属于第 i 类的置信度, 对应车辆、行人、路障和撒落物等 4 类中置信度最大的即为网络预测的类别。

ResNet 存在多次下采样, 原始网络完成下采样的方式如图 3(a) 所示。网络主结构在第 1 个 1×1 卷积时步长为 2, 在 shortcut 连接结构中也采用步长为 2 的 1×1 卷积。但这种下采样方式会随机丢弃一半的特征值, 不利于图像分类任务。因此, 所提算法对上述采样方式进行优化, 优化后如图 3(b) 所示, 主线结构将步长

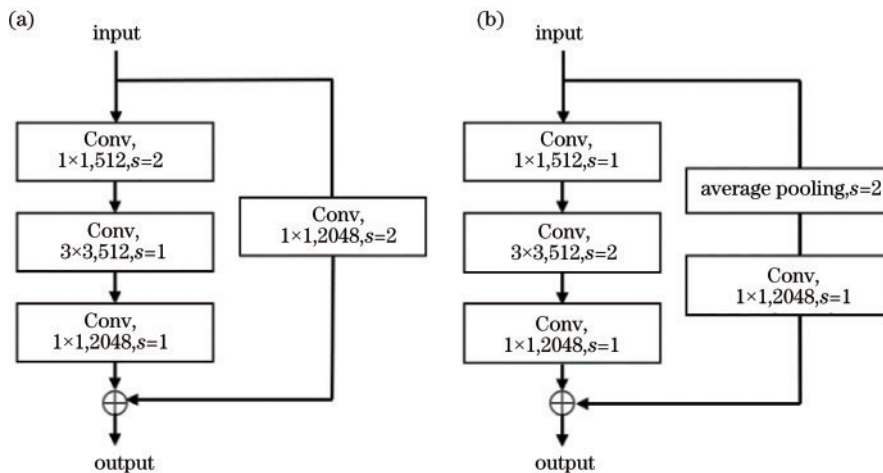


图 3 ResNet-50 下采样模块优化。(a) 优化前; (b) 优化后

Fig. 3 ResNet-50 down-sampling module optimization. (a) Before optimization; (b) after optimization

为 2 的下采样调整至 3×3 卷积处, shortcut 连接结构中修改 1×1 卷积的步长为 1, 然后在卷积前增加步长为 2 的 2×2 平均池化进行下采样。与原始结构中直接舍去一半的特征值相比, 这种下采样方式的运算速度几乎没有变化, 但可保留更多的有效信息, 更有利于完成分类任务。

2.3.4 网络训练及图像分类

将带有类别标签的图像数据集输入优化后的 ResNet-50 框架, 结合网络输出与标签计算网络损失, 然后采用梯度下降的方法更新网络权重。网络回归的目的是将图像分为车辆、行人、路障以及撒落物等 4 类, 因此使用交叉熵损失函数进行计算:

$$l(a, y) = - \sum_{i=1}^4 y^i \ln a^i, \quad (3)$$

式中: l 是损失函数; y 是标签; a 是元素。网络训练完成后, 将待检测图片输入训练后的网络, 网络将输出一个 1×4 的一维向量, 表示输入目标分别属于车、人、路障、撒落物的概率, 概率最大的一类即为网络的预测类别。

3 实验结果与分析

3.1 实验系统

为便于进行数据采集与实验验证, 本实验自主设计以电动代步车为载体的撒落物检测系统样车, 如图 4 所示。检测样车的主要传感器包含相机、激光雷达、GPS 定位系统、IMU 惯性导航系统等。表 1 为检测系统使用的主要设备的参数。

3.2 算法实验与分析

由于场地以及交通安全限制, 本检测车无法进入城市公路, 实验场地为校园内道路。实验时在路面人为放置撒落物。实验车采集的点云和图像如图 5 所示。其中, 每组图片的上半部分展示点云数据俯视图,



1 — lidar 3 — GPS 5 — industrial PC
2 — camera 4 — car monitor 6 — IMU

图 4 检测实验车和传感器安装示意图

Fig. 4 Schematic diagram of test vehicle and sensor installation

检测车位于点云中心圆的圆心处, 右向为车辆的前进方向, 每组图片的下半部分展示对应的图像数据。

3.2.1 路面物体提取与信息融合实验

该部分主要包括道路边缘提取、地面点云滤波和点云聚类这 3 个步骤和点云感兴趣区域在视觉图像中的映射。选取图 5 中的点云进行实验, 各步骤实验结果如图 6 所示。

图 6(a) 为道路边缘提取结果。首先对点云进行预处理, 通过直通滤波算法对道路外侧点云进行剪裁, 防止非感兴趣区域的干扰。然后分别提取视场中左右 2 个部分, 防止道路 2 条边界在直线拟合时相互干扰。每条扫描线选取 5 个点为一组计算高度差, 然后使用 RANSAC 算法拟合直线。在 2 条道路边缘线分别拟合完成后, 将左右 2 个部分进行点云合并得到整张点云图的道路边缘提取结果。

表 1 系统使用主要设备参数

Table 1 Main equipment parameters used by the system

Equipment	Model	Parameter
Lidar	Velodyne VLP-32C	Maximum measuring range 200 m
		Field of view 360°(H)×40°(V, -25°-15°)
		Vertical resolution minimum 0.33°
		Horizontal resolution 0.1-0.4°
Camera	DaHua 5131M/CU210	Resolution 1280×1024
		Pixel size 4.8 μm×4.8 μm
		Maximum frame rate 210 frame/s
		CMOS target surface size 1/2"
GNSS	MG910	Centimeter-level positioning
		Maximum output frequency 20 Hz
IMU	IMU560	Maximum output frequency 100 Hz
Industrial PC	DT-S2010MB-YH310MC4L	CPU: Intel i7-8700
		RAM 16 GB
		2 TB mechanical hard disk+128 GB SSD




图 5 实验采集数据示例

Fig. 5 Examples of experimental data collection




图 6 路面物体提取结果。(a)道路边缘提取;(b)地面点云滤波;(c)地面点剔除;(d)点云聚类

Fig. 6 Extraction results of road objects. (a) Road edge extraction; (b) ground point cloud filtering; (c) ground point elimination; (d) point cloud clustering

图 6(b)为地面点云滤波结果。根据道路边界拟合结果过滤掉道路两侧的点云,然后使用CSF算法进行点云分割。由于相机只拍摄检测车的前方,因此为了减少迭代次数、加快检测速度,点云处理只针对检测车前方区域,在图 6(b)中右向为车辆前进方向。图 6(c)为剔除绿色地面点后获取的含有噪声的路面物体的点云。

图 6(d)为地物点的点云聚类结果。白色边框内部分即为点云图中的感兴趣区域。由实验结果可以发现,DBSCAN算法能够将路面目标有效地聚类为白色边框内的点云团簇,提取感兴趣区域,而且可以有效消除图 6(c)中的噪声点。

将聚类后点云团簇中各数据点的位置坐标映射到对应的视觉图像中,并将投影后形成的像素点团簇的最小包围矩形截取出来,即可获得图像中的包含车辆、人、路障和公路撒落物的视觉图像感兴趣区域,如图 7 所示。根据实验结果可以发现,所提算法能够有效地进行路面目标的定位,提取出所有地面物体的感兴趣区域。




图 7 点云感兴趣区域在视觉图像中的映射结果

Fig. 7 Mapping result of point cloud region of interest in visual image

3.2.2 撒落物检测实验

本实验 CPU 为 Intel I9-7980xe, 显卡为 NVIDIA GeForce RTX 2080Ti, 内存为 32 GB。本实验数据集包含的路面图像的分辨率为 $224 \text{ pixel} \times 224 \text{ pixel}$, 共选取 1245 幅图像, 划分为 1045 幅训练集图像和 200 幅

测试集图像。通过人工对路面撒落物进行标注,最终输出检测为撒落物的预测概率。

为评估优化后 ResNet-50 的有效性,将点云目标投影至对应图像上,并截取投影后像素点集的最小包围矩形内的区域作为图像感兴趣区域。然后输入优化后的 ResNet-50 中进行分类,对公路撒落物检测算法进行定性和定量评估。图 8 红色边框内的部分表示该区域内撒落物的预测概率高于 50%,直观地展示算法对撒落物的检测情况。由图 8 可发现,优化后的 ResNet-50 框架对公路撒落物具有良好的检测效果,但也存在少数较小尺寸撒落物漏检的情况。图 9 显示测试图像中包含撒落物样例的预测概率。分析检测结



图 8 完整图像撒落物检测结果

Fig. 8 Detection result of scattered objects in a picture




图 9 撒落物图像块预测结果

Fig. 9 Prediction result of scattered object image block

果可得:优化后的 ResNet-50 模型对于尺寸较大的撒落物具有优秀的识别性能,预测概率在 90% 以上;当撒落物尺寸较小时,预测概率降低,但仍然可以实现 50% 以上的识别准确率;但当撒落物尺寸很小时,预测准确率陡降,此时会出现漏检的可能性。全部采集数据的检测结果统计如表 2 所示,不同尺寸的撒落物检测情况对比如表 3 所示。优化后的 ResNet-50 与优化前的 ResNet-50 的撒落物检测结果对比如表 4 所示。

表 2 撒落物检测算法实验结果

Table 2 Experimental results of scattered objects detection algorithm

Total number of road objects	Total number of falling objects	Predicted number of falling objects	Number of falling objects predicted to be true	Unpredictable number of falling objects	Predicted number of falling objects that are false	Precision / %	Recall / %
783	260	252	239	21	13	94.84	91.92

表 3 不同尺寸撒落物检测情况

Table 3 Detection of falling objects of different sizes

Scattered object size / cm	Actual number	Number of correctly detected	Recall / %
<10	17	6	35.29
10-30	191	181	94.76
>30	52	52	100.00

表 4 网络结构优化前后预测结果对比

Table 4 Comparison of prediction results before and after network structure optimization

Evaluation index	Before optimization	After optimization	Improvement
Precision / %	93.41	94.84	1.43
Recall / %	90.90	91.92	1.02

从表 2 可以看出,所提撒落物检测算法的检测精确率为 94.84%、召回率为 91.92%,均在 90% 以上,具有良好的检测准确度。从表 3 可以看出,系统对于尺

寸大于等于 10 cm 的撒落物检测效果较好,但对尺寸小于 10 cm 的撒落物检测效果还有待提高。其原因是本实验激光雷达的最佳检测判别区域为距离雷达 5.7~9.2 m 处,在该距离下 10 cm 的物体经激光雷达扫描后的点数约为 6~9。当撒落物尺寸小于 10 cm 时,扫描点数小于等于 5,在点云聚类阶段易被识别为噪声而被筛去,无法投影到图像中,导致检测效果较差。从表 4 可以看出,通过对 ResNet-50 的下采样模块进行优化,算法的检测精确率和召回率分别提高了 1.43 个百分点和 1.02 个百分点,验证了网络结构优化的有效性。综合定性及定量的实验结果分析,所提算法具有良好的公路撒落物检测准确度。

综合实验数据以及算法原理分析可知:影响系统检测精确率的因素为 ResNet-50 的分类能力;算法召回率主要受限于激光雷达的分辨率。后续可从这 2 个方面对算法的检测准确程度进行进一步优化。

4 结 论

针对当前公路撒落物的检测问题进行深入研究。在此基础上,提出一种基于图像与点云融合的公路撒落物检测算法。将撒落物检测问题分解为路面目标提取、点云和图像信息融合、撒落物目标分类等 3 个步骤。同时基于道路撒落物的特点、网络分类效果与数据处理量,选用 ResNet-50 作为撒落物特征分类的算法结构,并优化 ResNet-50 的采样过程,保留更多的有效信息。设计道路检测系统,使用实车采集数据并对所提算法进行准确性验证。所提算法平均检测精确率为 94.84%、召回率为 91.92%,具有良好的检测效果。在未来的研究过程中,所提算法还可以考虑网络结构优化、图像信息辅助点云聚类优化方法,并加入更多的传感器,提升整体系统的实用性。

在算法速度方面,所提算法目前尚未实现实时检测。由于所提算法的目的是提高撒落物检测的精确率与召回率,因此算法框架较为复杂,需要多次迭代运算,算法速度较慢。未来研究过程中,将考虑使用并行计算等手段对算法运算速度进行优化,进而实现实时检测。

参 考 文 献

- [1] 任婷婷. 基于视频图像处理的城市道路污染检测与识别[D]. 太原: 太原科技大学, 2015: 11-25.
Ren T T. Detection and identification of urban road pollution based on video image processing[D]. Taiyuan: Taiyuan University of Science and Technology, 2015: 11-25.
- [2] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [3] 赵亮, 胡杰, 刘汉, 等. 基于语义分割的深度学习激光点云三维目标检测[J]. *中国激光*, 2021, 48(17): 1710004.
Zhao L, Hu J, Liu H, et al. Deep learning based on semantic segmentation for three-dimensional object detection from point clouds[J]. *Chinese Journal of Lasers*, 2021, 48(17): 1710004.
- [4] 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, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6526-6534.
- [5] 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.
- [6] 张双喜. 基于雷达与相机的无人驾驶智能车障碍物检测技术研究[D]. 西安: 长安大学, 2013: 36-50.
Zhang S X. Research on obstacle detection technology based on radar and camera of driverless smart vehicles [D]. Xi'an: Changan University, 2013: 36-50.
- [7] 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.
- [8] 化春键, 潘瑞, 陈莹. 基于改进ORB-RANSAC的双目测距方法[J]. *激光与光电子学进展*, 2021, 58(22): 2215002.
Hua C J, Pan R, Chen Y. Binocular ranging method based on improved ORB-RANSAC[J]. *Laser & Optoelectronics Progress*, 2021, 58(22): 2215002.
- [9] Hu K L, Wang T M, Li Z, et al. Real-time extraction method of road boundary based on three-dimensional lidar[J]. *Journal of Physics: Conference Series*, 2018, 1074: 012080.
- [10] 邵靖滔, 杜常清, 邹斌. 基于点云簇组合特征的激光雷达地面分割方法[J]. *激光与光电子学进展*, 2021, 58(4): 0428001.
Shao J T, Du C Q, Zou B. Lidar ground segmentation method based on point cloud cluster combination feature[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0428001.
- [11] 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.
- [12] 张长勇, 陈治华, 韩梁. 基于改进DBSCAN的激光雷达障碍物检测[J]. *激光与光电子学进展*, 2021, 58(24): 2428005.
Zhang C Y, Chen Z H, Han L. Obstacle detection of lidar based on improved DBSCAN algorithm[J]. *Laser & Optoelectronics Progress*, 2021, 58(24): 2428005.
- [13] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [14] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [15] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-05-04]. <https://arxiv.org/abs/1409.1556>.
- [16] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.