

DOI: 10.19650/j.cnki.cjsi.J2311227

雨雪天气下的激光雷达滤波算法研究^{*}

陈熙源, 戈明, 姚志婷, 周云川

(东南大学仪器科学与工程学院 南京 210096)

摘要:在雨雪等恶劣天气下,由于雨雪颗粒的遮挡,激光雷达的性能会受到严重影响,给三维目标检测带来了很大困难。针对这个问题,提出了一种基于马氏距离的动态离群点滤波算法;首先通过建立 KD 树,根据不同欧氏距离计算离群点的马氏距离,去除点云雨雪噪声;最后将该算法应用于目标检测。经过加拿大恶劣天气公开数据集(CADCD)和实际实验的验证,在中雪和大雪天气下,与 DROR 滤波方法对比,本文提出的滤波算法精确率分别相对提高了 7.88%, 7.72%;在实际雨天实验中,本文算法精确率比 DROR 滤波相对提高了 10%。在目标检测应用方面,与仅采用 Pointpillars 的算法相比,采用该滤波的检测算法车辆和行人的检测精度也分别相对提高了 19.26%, 20.39%, 在数据集和实际实验场景下均验证了本文算法的有效性。

关键词:雨雪天气;点云滤波;激光雷达;三维目标检测

中图分类号: TH86 TP391 文献标识码: A 国家标准学科分类代码: 510.4

Research on Lidar filtering algorithm for rainy and snowy weather

Chen Xiyuan, Ge Mingming, Yao Zhiting, Zhou Yunchuan

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: In bad weather such as rainy and snowy, the performance of LiDAR can be seriously affected due to the block of rain and snowflakes, which brings great difficulties to 3D target detection. Aiming at this problem, a dynamic outlier filtering algorithm based on the Mahalanobis distance is proposed. First, by establishing the KD tree, the Mahalanobis distance of outlier points is calculated to remove snowflakes noise with different Euclidean distances. After the verification of the Canadian Adverse Driving Conditions open Dataset and practical experiments, the accuracy of the filtering algorithm proposed in this paper is improved by 7.88% and 7.72% respectively, compared with the DROR filtering algorithm in medium and heavy snowy weather. In practical rainy experiments, the algorithm proposed in this study exhibited a relative improvement of 10% precision compared to the DROR filtering algorithm. For target detection applications, the detection accuracy of vehicle and pedestrian detection via the filtering algorithm is also improved by 19.26% and 20.39% respectively, compared to the algorithm using only Pointpillars, which verifies the effectiveness of this method in dataset and real experimental scenarios.

Keywords: snowy weather; pointcloud filtering; LiDAR; 3D target detection

0 引言

激光雷达是环境感知领域中重要的传感器之一,在目前的传感器技术下,激光雷达在雨雪雾等不利环境下工作仍然会出现较大的问题^[1],据调查有接近 22% 的自动驾驶交通事故都是和天气情况有关^[2]。在大雪天气中,激光雷达的激光束容易被雪花颗粒遮挡,从而受到干扰,造成精度下降;在雨天环境中,由于激光发射波密度较高,遇到雨滴会发生反射以及折射形成误判^[3],传感器

在不同环境下的性能会不断变化,这些环境干扰都会给点云信息引入很大的噪声^[4],给接下来的三维目标检测带来巨大挑战,然而目前大部分的激光雷达检测算法在相对良好的天气情况下进行提出和改进的,国内鲜有学者分析三维目标检测算法在雨雪天气下的表现。

国外有一些学者针对这些恶劣天气条件开展了研究,关于雨雪去噪的算法,主要可以分为两类,一类是以深度学习为基础的算法,原理是设计一种针对雨雪特征的提取网络,通过大量数据训练,进而去除噪声,缺点是模型适用性较差;另一类是物理聚类或者滤波算法,通过

分析点云特性,进行聚类或者滤波,缺点是损失了较多的点云信息。

在深度学习算法方面,Heinzler 等^[5]首次提出了以深度学习为基础的恶劣天气下去噪网络,通过大量数据训练一个 WeatherNet,能够滤除点云在雨天和大雾等天气下的噪点,优点是处理速度较快;Lin 等^[6]通过改进传统的三维目标检测算法,提出了一种适用于雪天的检测网络,利用最大平均偏差(maximum mean discrepancy, MMD)块,得到域特征表示的分布,并计算训练损失输出检测结果;在聚类和滤波算法方面,文献[7-8]设计一种自适应距离参数,动态调节 DBSCAN 聚类范围,在雪天取得了很好的聚类效果;统计滤波(statistical outlier removal, SOR)和半径滤波(radius outlier removal, ROR)是最常用的点云噪声滤波方法^[9],原理是建立 KD 树,遍历每个点云到其他点的半径距离来进行滤波,缺点是准确率较低,Charron 等^[10]针对这点提出了动态离群点滤波(DROR),设计了一个根据距离调节半径的 KNN 算法;在传感器层面上,国内有学者采用精确的标定算法^[11],多传感器融合等方法提高对稀疏点云检测精度^[12];朱玲嫏等^[13]在信号角度,提出了一种激光雷达回波信号的噪声抑制方法。

在激光雷达目标检测方面,早期的 3D 检测算法以图像为主,通过投影或者融合的方式,利用传统图像数据处理的方式进行特征提取,直到 2017 年 Qi 等^[14]提出了首个以纯点云数据输入的网络 Pointnet,为以后点云特征提取确定了方向,随后他又提出了 Pointnet++^[15],通过聚类的方式生成候选区域对于 3D 点云数据进行分类;Zhou 等^[16]提出了端对端的检测网络 VoxelNet,通过体素分割的方法使用 Pointnet 网络进行特征提取并输出检测结果。

目前激光雷达检测算法主要可以分为两类:单步检测算法和两步检测算法。其中,单步检测算法原理是将 3D 维度的点云进行体素化编码转换为 2D 的伪图像数据,再利用如 SSD^[17],YOLO^[18]等检测算法生成检测框,并通过算法进行筛选,输出目标的 3D 检测框;优点是检测速度较快,缺点是检测精度较低,代表算法有 SECOND^[19],Pixon^[20],Pointpillars^[21],其中 Pointpillars 算法的平均检测速度达到了 62 Hz,最快可达 105 Hz,同时有着不低的精度,在自动驾驶领域有着广泛的应用;两步检测算法的原理是第 1 阶段利用特征网络提取生成 Region Proposals,对点云数据进行语义分割,将点云分为前景点和背景点;第 2 阶段优化一阶段生成的候选框,并且生成置信度标签,输出最终检测的检测框,特点是检测精度较高,缺点是计算量较大,速度较慢,代表算法有 PointRCNN^[22],PVRCNN^[23],3DSSD^[24]等。前人对以上

算法做出了很多改进,但是目前仍然存在如下 3 个不足:

1) 传统的滤波算法会损失较多的点云信息,准确率较低;2) 目前的三维目标检测算法不适用于雨雪天气;3) 缺少对于雨雪天气的激光雷达性能分析;针对以上问题,本文作出了以下工作:分析激光雷达数据在雨雪天气下的特性,以及目前主流的滤波算法在雨雪天气下的表现,提出了一种基于马氏距离的动态离群点滤波方法去除雨雪噪点,将其应用于目标检测算法输出检测结果,并进行评估对比。

1 基于马氏距离的离群点滤波算法

1.1 雨雪天气点云特性

激光雷达的原理是通过发射激光束并接收反射的激光束来获取点云坐标和反射强度信息,这些生成的点云数据具有如下 3 种特性:1)无序性,2)置换不变性,3)旋转不变性;在雨雪天气下,产生的稀疏点云数据容易受到雨雪噪点的干扰;为了进一步分析点云的特性,采用加拿大不利驾驶条件数据集(Canadian adverse driving conditions dataset, CADCD)数据集进行数据分析,如图 1 所示,该图是数据集 Velodyne-32C 型号激光雷达采集的一帧点云数据,通过点云读取算法处理可以绘制以下图像。

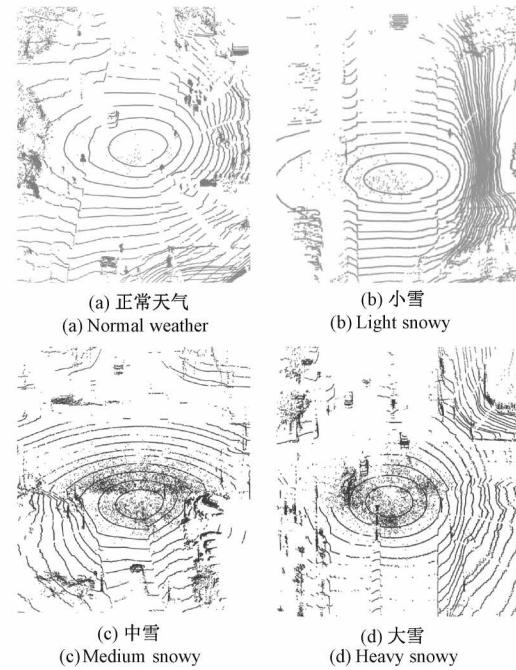


图 1 不同天气下雷达点云图

Fig. 1 Pointcloud in different weather

可以看出,激光雷达扫描的点云数据具有近密远疏的特点,随着距离的增大,点云越来越稀疏;在中雪和大雪环境下,由于激光雷达被雪花和雨水遮挡,点云噪点数

据明显增多,而且障碍物的点云信息已经被严重干扰;根据雪花的物理特性^[25],雪花的密度 ρ 和分布函数 $n(r)$ 可以表示如下:

$$\begin{cases} \rho = \frac{C}{0.2r} \\ n(r) = N_o e^{Ar} \end{cases} \quad (1)$$

式中: C 是常数, r 为雪花的半径, N_o 是关于降水量和积雪密度的函数, A 是与积雪密度有关的常数;若以 H_c 表示为激光传播过程中,雪花噪声对激光雷达的吸收和散射效应^[26],则可以建模为:

$$H_c(R) = \frac{T^2(R)}{R^2} \xi(R) \quad (2)$$

式中: R 为距离变量, $T(R)$ 为光的传播损失, $\xi(R)$ 可以表示为发射与接收比的交叉函数,即为:

$$\xi(R) = \begin{cases} 0, & R < R_1 \\ \frac{R - R_1}{R_2 - R_1}, & R_1 \leq R < R_2 \\ 1, & R \geq R_2 \end{cases} \quad (3)$$

式中: R_1 和 R_2 为距离的边界常量。

1.2 基于马氏距离的滤波算法设计

本文提出了一种马氏距离的动态离群点滤波算法,其中半径搜索原理如图 2 所示;对于点云中的每一个点 p_i ,给定一个搜索半径 r_s ,搜索领域半径内的点数;设 $N_{threshold}$ 为点云数目阈值,若邻域内的点数 $N < N_{threshold}$,则判定该点为噪点去除。

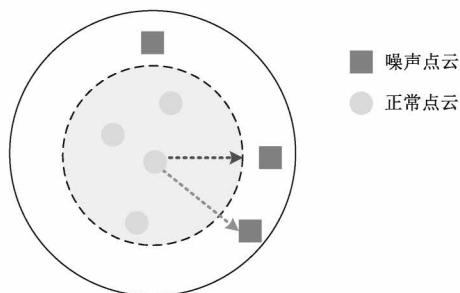


图 2 点云滤波原理

Fig. 2 Pointcloud filtering procedure principle

该算法的具体设计流程如图 3 所示,步骤如下:

- 1) 首先获取单帧点云数据,然后将点云投影到 xy 平面,建立 KD 树;
- 2) 接着遍历一帧点云中的点,以其中一点为中心计算每个点到该点的欧氏距离,接着作如下判断:
- 3) 点云根据欧氏距离的模来判定进行 KNN search 还是 RadiusNN search,若大于设定距离,则远处点云需要通过具体阈值判定;即假设对于点云中的每一个点 p_i ,

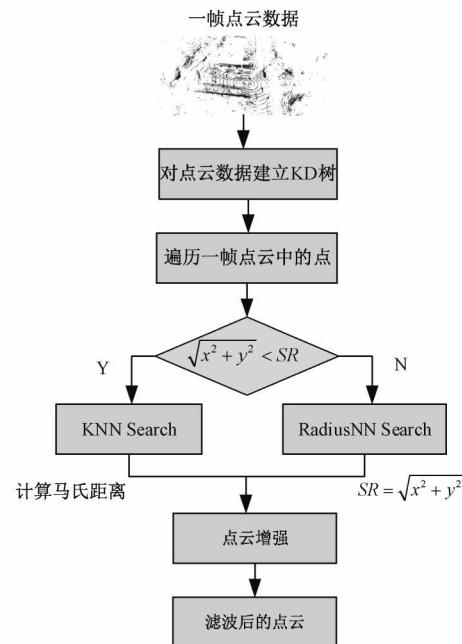


图 3 基于马氏距离的动态离群滤波流程图

Fig. 3 Dynamic outlier filtering algorithm based on the Mahalanobis distance procedure

(1) 若 $d = \sqrt{x^2 + y^2} < r_s$; 采用 KNN search 算法搜索构建的 KD 树内最近的 k 个点,即与各个结点比较结果向下访问 KD 树,直至达到叶子结点,并判断是否需要进行回溯操作,最后返回最近的 k 个点云:

$$\mathbf{P}_k = \{p_1, p_2, \dots, p_k\} \quad (4)$$

则该 k 个点的均值可以表示为:

$$\begin{cases} \bar{X} = \frac{1}{k} \sum_{i=1}^k x_i \\ \bar{Y} = \frac{1}{k} \sum_{i=1}^k y_i \end{cases} \quad (5)$$

则协方差可以表示为:

$$\begin{cases} \text{Cov}(X, X) = \frac{1}{k} \sum_{i=1}^k (x_i - \bar{X})(x_i - \bar{X}) \\ \text{Cov}(X, Y) = \frac{1}{k} \sum_{i=1}^k (x_i - \bar{X})(y_i - \bar{Y}) \\ \text{Cov}(Y, Y) = \frac{1}{k} \sum_{i=1}^k (y_i - \bar{Y})(y_i - \bar{Y}) \end{cases} \quad (6)$$

协方差矩阵为:

$$\boldsymbol{\Sigma} = \begin{pmatrix} \text{Cov}(X, X) & \text{Cov}(X, Y) \\ \text{Cov}(X, Y) & \text{Cov}(Y, Y) \end{pmatrix} \quad (7)$$

假设协方差矩阵均满秩,则马氏距离计算公式为:

$$D_M(x, y) = \sqrt{(x - \bar{X})^T \boldsymbol{\Sigma}^{-1} (y - \bar{Y})} \quad (8)$$

若满足 $D_M > D_s$, 则判定该点为雨雪噪点并去除。

- (2) 相反若满足 $d = \sqrt{x^2 + y^2} > r_s$; 对于点云采用 RadiusNN search 搜索以 d 为半径范围内的点,若搜索点

的个数 $k < k_{\min}$, 则判定该点为噪点数据, 并进行剔除; 最终返回滤波后的点云数据。

根据距离参数分辨出正常点云与噪点, 最后进行滤波, 如图 4 所示; 基于马氏距离的滤波算法根据不同距离下扫描的点云采用不同的搜索算法进行点云搜索。

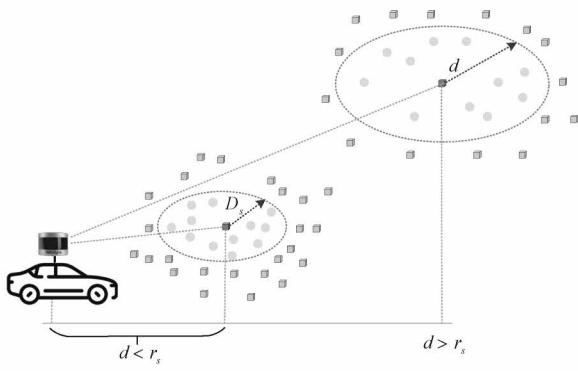


图 4 不同距离下的点云处理方法

Fig. 4 Pointcloud processing method at different distances

2 滤波方法在检测中的应用

考虑到算法的实时性和精度的要求, 本文采用目标检测算法对滤波后的点云进行处理, 并且将其改写到 ROS 系统实现实时检测与滤波。

2.1 点云体素化编码

首先处理后的点云数据特征为 (x, y, z, r) , x, y, z 分别为世界坐标系下点云在空间中沿 Ox, Oy, Oz 三轴的欧式距离, r 为点云的反射强度值; 然后将点云空间按照体素网格划分为多个立方体, 如图 5 所示。

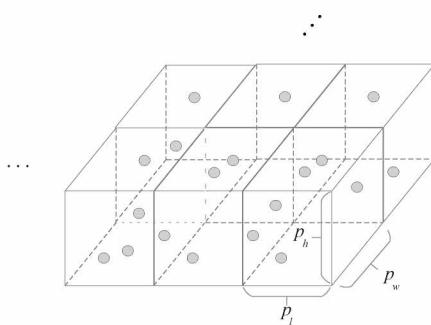


图 5 点云体素分割

Fig. 5 Point voxel segmentation

假设点云空间的长宽高分别为 L, W, H , 每个立方体的长宽高分别为 p_l, p_w, p_h , 则总共可以划分为 $\left(\frac{L}{p_l} \times \frac{W}{p_w} \times \frac{H}{p_h}\right)$ 个体素, 则每个点云数据的数据特征可

以增强为:

$$\mathbf{V} = \{p_i = (x, y, z, r, x_c, y_c, z_c, x_p, y_p, z_p) \in \mathbf{R}^{10}\}_{i=1,2,\dots,n} \quad (9)$$

其中:

$$\begin{cases} x_c = (x - \sum_{i=1}^N x_i) \\ y_c = (y - \sum_{i=1}^N y_i) \\ z_c = (z - \sum_{i=1}^N z_i) \end{cases} \quad (10)$$

式中: N 为每个体素中最大的点云数目, x_c, y_c, z_c 为体素中当前点相对于所有点均值的偏差; x_p, y_p, z_p 为当前点相对于体素中心点的偏移距离。

2.2 特征提取与目标检测

编码后的点云数据需要采用类似于 Pointnet 的网络进行点云特征提取, 流程如图 6 所示; 然后按图像特征还原到三维数据形成伪图像数据; 接着需要对伪图像数据进行降采样并进行拼接, 最后送入 SSD 检测算法输出目标检测结果。其中特征提取网络模型的损失函数定义为:

$$\mathcal{L} = \frac{1}{N_{pos}} (\beta_{loc} \mathcal{L}_{loc} + \beta_{cls} \mathcal{L}_{cls} + \beta_{dir} \mathcal{L}_{dir}) \quad (11)$$

$$\mathcal{L}_{cls} = -\alpha_a (1 - p^a)^\gamma \log p^a \quad (12)$$

$$\mathcal{L}_{loc} = \sum_{b \in (x, y, z, w, l, h, \theta)} SmoothL1(\Delta b) \quad (13)$$

其中, \mathcal{L} 为总的损失函数, \mathcal{L}_{cls} 为分类的损失函数, \mathcal{L}_{loc} 为位置的损失函数, \mathcal{L}_{dir} 为方向分类损失函数; $\beta_{loc}, \beta_{cls}, \beta_{dir}$ 分别为位置损失函数的系数, 分类损失函数的系数以及方向分类损失函数的系数; 参数 p 为样本为正值的概率; α_a 为权重系数, α, γ 为系统的超参数; $(x, y, z, w, l, h, \theta)$ 为预测框的位置坐标, 长宽高, 航向角参数。SmoothL1 为一损失函数; Δb 为预测值与真值的偏移。

3 CADCD 数据集验证

实验采用 CADCD 数据集来验证算法的有效性; 数据集包含了不同种类的交通状况, 并且伴随有不同程度的降雪。如图 7 所示, 采集车辆装备有一台 VLP-32C 激光雷达(Velodyne), 分别有水平 0.2° 和垂直 0.3° 的角分辨率, 实验采样频率为 10 Hz , 最远探测距离 200 m 。

本文选取不同场景下的数据进行测试训练, 实验场景分别覆盖多云, 小雪, 中雪以及大雪等天气, 如图 8 所示。实验设备为: AMD Ryzen 5 5600 G CPU @ NVIDIA GeForce RTX 3090 GPU 的电脑, ubuntu20.04 的系统。

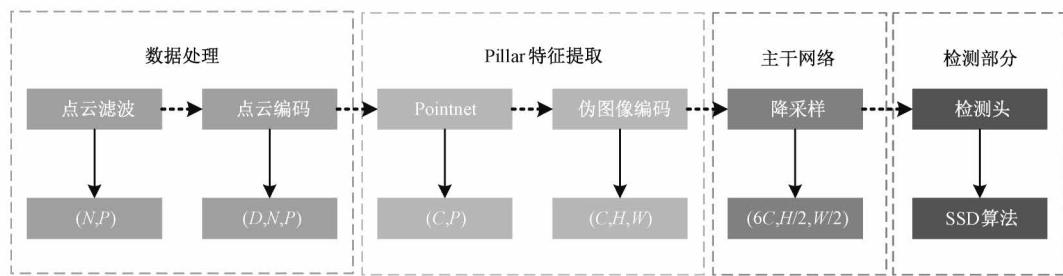


图 6 点云目标检测流程

Fig. 6 Pointcloud detection procedure



图 7 CADCD 数据集采集设备

Fig. 7 CADCD dataset collecting device

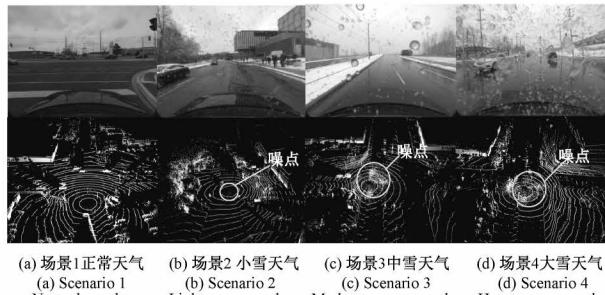


图 8 4 种不同场景下的点云图

Fig. 8 Pointcloud in four different scenes

3.1 雨雪噪声统计

在分别对点云图像进行校准之后,本文使用 Cloudcompare 软件对点云数据进行标注,设置噪声标签和正常点云标签,则可对不同天气情况下的点云数据进行粗略统计,雪花数目随欧氏距离的分布如图 9 所示。根据统计信息,可以发现雨雪噪点数目随着距离的增加呈现先上升后下降趋势,且 90% 以上的噪点都在集中在以激光雷达为中心的 15 m 半径范围之内。

将不同欧氏距离内的噪点相加并进行统计,得到如表 1 所示的数据,由表 1 可以看出在 4 种不同的天气情况下,雪花噪点均集中在 [5 m, 10 m] 范围内,且在距离大于 15 m 时噪点数目大幅度下降;另外激光雷达的噪点数据与天气情况有着很大的关系,天气越恶劣,呈现的噪点数目越多。

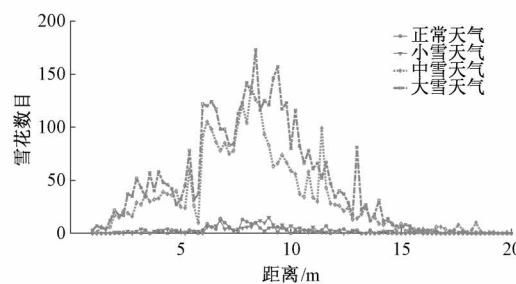


图 9 雪花数目-欧氏距离的分布图

Fig. 9 Snowflake distribution at different Euclidean distance

表 1 激光雷达雨雪噪点统计

Table 1 LiDAR Snow points statistics

距离/m	[0, 5]	[5, 10]	[10, 15]	[15, 20]
正常天气	15	139	15	3
小雪天气	30	138	49	2
中雪天气	45	2 001	713	77
大雪天气	607	2 658	43	6

3.2 滤波效果评估

选取中雪这一场景,分别采用不同的滤波算法进行比较,如图 10 所示,ROR 滤波和 SOR 滤波去除了大部分噪点,但是损失了部分近处的点云信息,噪声也有部分残留;DROR 滤波具有较好的滤波效果,但是近处点云信息经过滤波之后,有较大损失;由对比可以看出,本文提出的基于马氏距离的滤波算法也损失了部分的远处点云,但是可以滤除绝大部分的雨雪噪声,同时算法能较好的保留近处的点云信息。

为了进一步评估雨雪滤波器的性能,本文通过计算精确率(Precision)和召回率(Recall)来进行比较,具体公式如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (14)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (15)$$

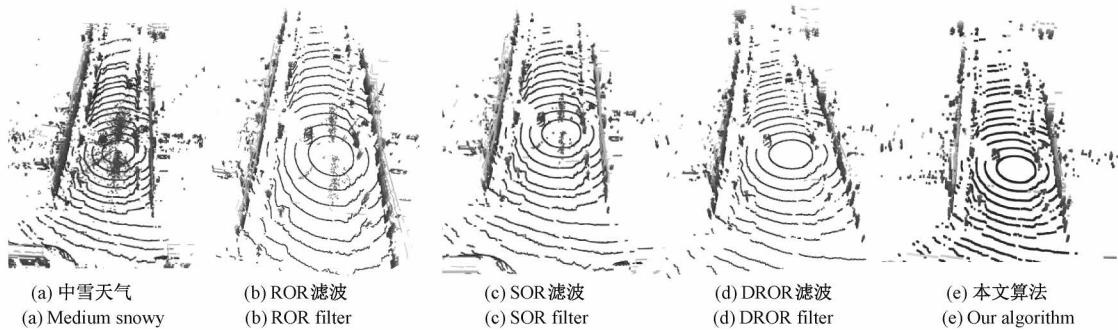


图 10 不同滤波方法的对比
Fig. 10 Comparison of different filtering algorithms

其中,正类为雪花,负类为正常点云; TP 代表真阳性,即模型中雪花被正确判定为雪花的数目; FP 代表假阳性,即模型中正常点云被判定为雪花的数目; FN 代表假阴性,即雪花被判定为正常点云的数目。考虑到远处稀疏的噪点信息对点云几乎不构成影响,可将点云设置为 $x \in [-40, 40]$ m, $y \in [-40, 40]$ m 范围内。一组点云数据约 $6 \times 10^4 \sim 8 \times 10^4$ 个点,分别取 100 组中雪和大雪天气的点云数据,计算精确率和召回率的均值,结果如表 2 所示。

表 2 准确率和召回率统计

Table 2 Precision and recall statistics

算法	中雪天气		大雪天气	
	Precision	Recall	Precision	Recall
SOR	0.173 3	0.323 9	0.001 4	0.003 0
ROR	0.562 1	0.645 4	0.417 1	0.729 1
DROR	0.728 8	0.881 0	0.655 6	0.948 3
本文算法	0.786 2	0.852 9	0.706 2	0.918 8

由表 2 可以看出,在中雪天气下,相比于 SOR 滤波,ROR 滤波,本文基于马氏距离的动态离群点滤波算法的精确率和召回率更高,与 DROR 滤波相比,本文的算法在召回率上不占优势,但是精确率相对提升了 7.88%;在大雪天气下,几种不同滤波器的性能均有所下降,与 DROR 滤波方法对比,本文提出的滤波算法精确率相对提高了 7.72%。

3.3 检测效果评估

为了验证检测效果,我们通过数据集进行评估实验,其中采用的 CADCD 数据集总共包括 7 065 个标注样本,在每一帧点云图像中,车辆还包括泊车,停车,移动三种属性;分别随机选取其中 2 000 份点云数据集作为训练集,1 000 份数据集作为验证集,主要将标签分为 [Car, Pedestrian] 进行比较。

本文采用 CADCD 数据集训练和验证,进行对比实验,中雪场景下行人和车辆的检测结果如图 11 所示,由点云图可以看出,本文提出的算法损失了部分激光雷达扫描的点云信息,但是能够在雨雪天气下,去除大部分的噪点;如图所示,深蓝色框为本文算法检测到而 Pointpillars 算法漏检的障碍物,可以看出与仅采用 Pointpillars 的检测算法对比,本文提出的算法可以在一定程度上降低漏检率。

接着对目标检测结果进行评估,考虑到车辆标签数目远比行人标签多,且在点云图像中行人扫描的点数较少,难以区分,因此选用不同的 IoU 评定标准。分别在对不同行人和车辆采用不同的 IoU 标准进行评估,统计的结果如表 3 所示,由表 3 可以看出,对于车辆的检测准确率,相比于仅采用 Pointpillars 的检测算法,本文提出的算法在 $IoU=0.7$,以及 $IoU=0.5$ 时分别提高了 19.26%,10.46%。

表 3 雨雪天气下 3D 视角目标检测结果对比

Table 3 Target detection result at 3D view in snowy

算法	weather				%	
	车辆(3D)		行人(3D)			
	$IoU=0.7$	$IoU=0.5$	$IoU=0.5$	$IoU=0.25$		
PVRCNN 算法	59.819 7	70.122 9	63.513 2	79.256 3		
Second 算法	54.382 9	62.251 4	44.548 8	62.979 9		
Pointpillars 算法	51.710 4	63.373 4	42.640 3	65.7612		
本文算法	61.667 4	70.000 3	51.333 0	76.469 6		

对于行人的识别结果在 $IoU=0.5$ 和 $IoU=0.25$ 的情况下,相比于仅采用 Pointpillars 的算法分别提高了 20.39%,16.28%;与二阶段检测算法 PVRCNN 进行对比,可以看出在 $IoU=0.7$ 和 $IoU=0.5$ 两种算法的车辆识别准确率相近,在行人检测准确率上 PVRCNN 表现较好,但是 PVRCNN 时间复杂度更高,耗用更多的计算资源,本文提出的算法结构更为简单,在同等算力下更占优势。

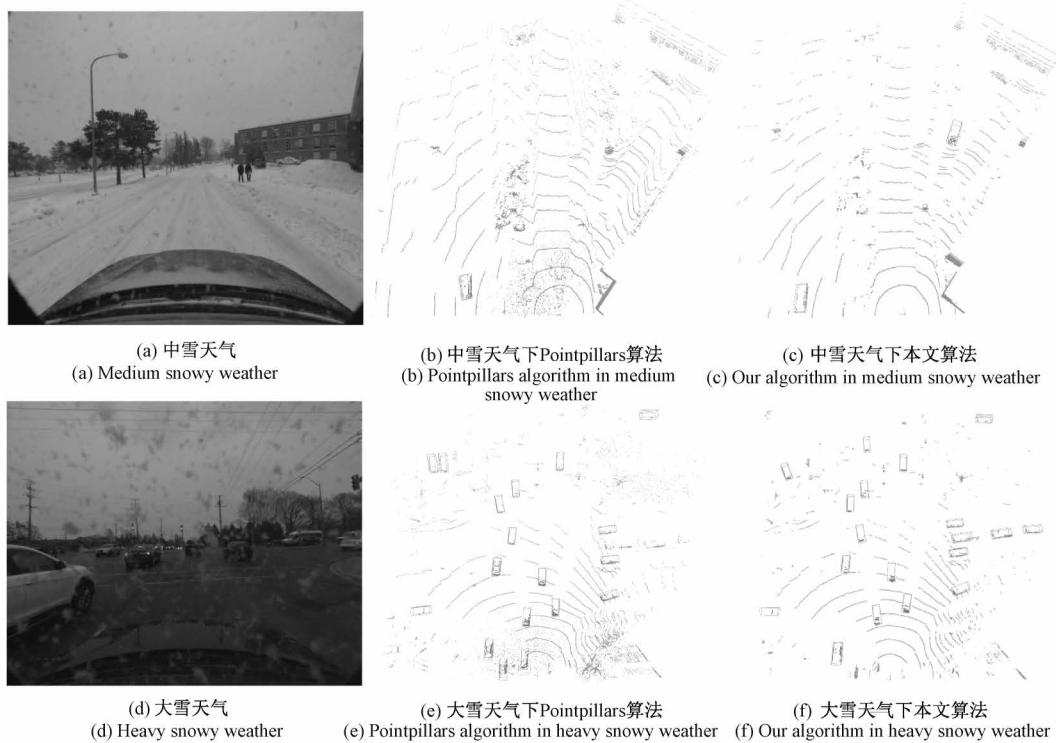


图 11 检测结果对比
Fig. 11 Comparison of detection result

4 实验验证

为了验证本文算法的有效性,本文采用了基于小车的实验平台,如图 12 所示,小车搭载了镭神 C32 型号的 32 线激光雷达以及双目视觉相机,实验环境为中雨天气,相机和激光雷达的采集频率均为 10 Hz,小车控制板卡装有 Ubuntu18.04 的操作系统,外置 USB 存储设备,完成点云滤波以及采集 rosbag 数据的操作。

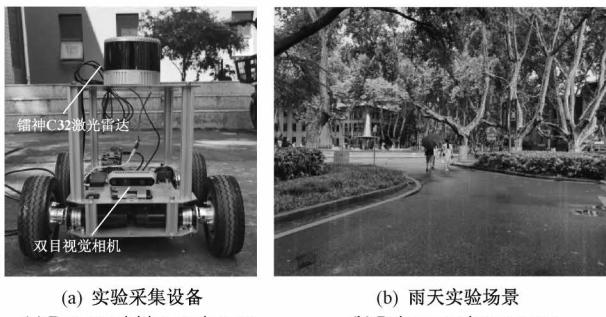


图 12 雨天实验
Fig. 12 Rainy experiment

将雨天采集的点云数据进行标定和畸变校正,然后采用算法绘制一帧的点云数据,然后分别采用不同的滤波算法,如图 13 所示;可以看出在雨天环境下,近处点云

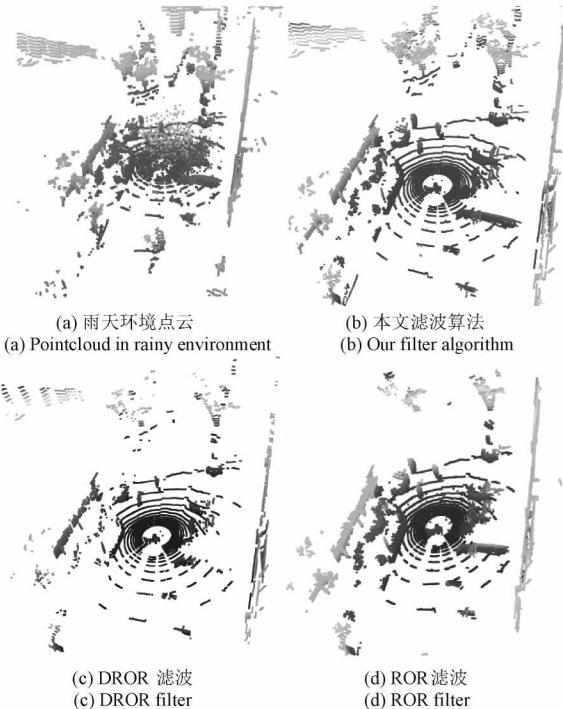


图 13 滤波算法对比
Fig. 13 Comparison of filter algorithm

噪声较多,远处噪声较少;采用滤波算法会损失部分点云的数据,且本文提出的滤波算法相比于 ROR 滤波和

DROR 滤波对比能够去除更多噪声点云,同时与 DROR 算法相比,本文的算法也能保留更多的点云信息。

随机选取 100 帧雨天环境不同场景下采集的点云,使用 CloudCompare 软件进行点云分割,对于每个点云设置相应的标签,分别采用不同的滤波算法,最后计算精确率(Precision)和召回率(Recall)均值来进行比较,得到如下表 4 数据,由表 4 分析可以看出,在雨天环境下本文的算法在召回率上与 DROR 相差不大,但是精确率相比于 DROR 提高了 10%。

表 4 雨天环境下准确率与召回率统计

Table 4 Precision and Recall in rainy environment statistics

算法	中雨天气	
	Precision	Recall
ROR	0.4877	0.6310
DROR	0.6553	0.8675
本文算法	0.7205	0.8463

在目标检测应用方面,将采集的点云进行滤波,然后采用目标检测算法输出检测框,得到图 14 所示的检测图像。可以看出本文的算法会损失一定程度的点云信息,但是可以去除大部分的点云噪声,且本文的检测算法可以检测到更多的车辆障碍物信息,检测效果更好。

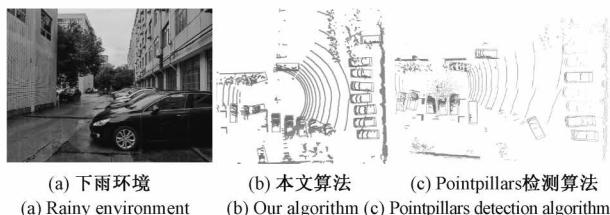


图 14 检测

Fig. 14 Comparison of detection algorithm

考虑到人工标注的数据与官方开源数据集有较大的精度差距,且人工标注成本较高,所以检测目标框与标注目标框外形误差和位置误差进行评估,计算公式为:

$$e_1 = \sqrt{(W - W')^2 + (L - L')^2} \quad (16)$$

$$e_2 = \sqrt{(x - x')^2 + (y - y')^2 + (z - z')^2} \quad (17)$$

其中, e_1 为输出检测框与真实标注框的外形误差, e_2 为输出检测框与真实标注框的位置误差; W, W', L, L' 分别为真实标注框的外形大小和检测框的外形大小; (x, y, z) , (x', y', z') 分别为真实标注框的位置和检测框的位置; 人工标注 20 组点云数据,统计不同距离的误差结果计算均值; 如图 15 所示,在实际雨天环境下,本文算法相比于 Pointpillars 算法,在距离小于 20 m 时,与人工标注框的位置误差更小,且波动也更小,效果更好; 在此范围内

Pointpillars 算法位置误差更大,误差较大的原因可能由于噪声干扰导致算法没有检测到部分的目标; 其中在距离大于 20 m 时,本文算法由于损失了部分点云信息,对于远距离的点云检测框输出有着一定影响。

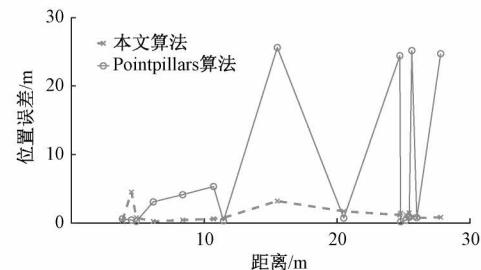


图 15 检测框与真值的位置误差

Fig. 15 Localization error between detection box and ground truth

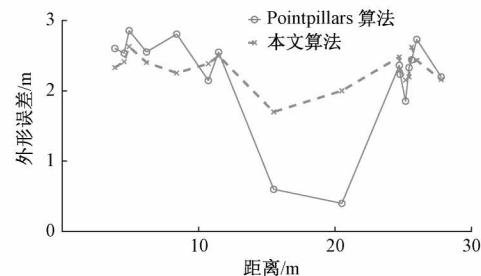


图 16 检测框与真值的外形误差

Fig. 16 Shape error between detection box and ground truth

另外,由图 16 可以看出本文的算法相比于 Pointpillars 算法在雨天环境下的外形误差更小,有着更高的检测框精度。

5 结 论

针对雨雪天气下,激光雷达受严重干扰,点云数据被引入较多噪声的问题,本文提出了一种基于马氏距离的动态离群点滤波算法,并且着重分析了雨雪天气下激光雷达的性能表现,同时将滤波结果进行点云编码,结合目标检测算法输出目标检测结果。实验结果表明:本文提出的滤波算法能够较好的抑制雨雪噪声,而基于马氏距离的滤波检测算法能够有效提升雨雪天气下的目标检测准确率; 在后续的研究中,计划建立更准确的雨雪天气模型以及适应的网络结构,提高激光雷达目标检测精度与速度。

参 考 文 献

- [1] VATTEM T, SEBASTIAN G, LUKIC L. Rethinking LiDAR object detection in adverse weather

- conditions [C]. Proceedings of the IEEE International Conference on Robotics and Automation, 2022: 5093-5099.
- [2] YU R, XIONG Y, ABDEL-ATY M. A correlated random parameter approach to investigate the effects of weather conditions on crash risk for a mountainous freeway [J]. Transportation Research Part C: Emerging Technologies, 2015, 50: 68-77.
- [3] 孙朋朋,赵祥模,蒋渊德,等. 降雨条件对车载激光雷达性能影响的试验研究 [J]. 中国公路学报, 2022, 35(11): 318-328.
- SUN P P, ZHAO X M, JIANG Y D, et al. Experimental study of influence of rain on performance of automotive LiDAR [J]. China Journal of Highway and Transport, 2022, 35(11): 318-328.
- [4] HEINZLER R, SCHINDLER P, SEEKIRCHER J, et al. Weather influence and classification with automotive lidar sensors [C]. Proceedings of the IEEE Intelligent Vehicles Symposium, 2019: 1527-1534.
- [5] HEINZLER R, PIEWAK F, SCHINDLER P, et al. CNN-based lidar point cloud de-noising in adverse weather [J]. IEEE Robotics and Automation Letters, 2020, 5(2): 2514-2521.
- [6] LIN J, YIN H, YAN J, et al. Improved 3D object detector under snowfall weather condition based on LiDAR point cloud [J]. IEEE Sensors Journal, 2022, 22(16): 16276-16292.
- [7] WU J, XU H, SUN Y, et al. Automatic background filtering method for roadside LiDAR data [J]. Transportation Research Record, 2018, 2672 (45): 106-114.
- [8] WU J, XU H, ZHENG J, et al. Automatic vehicle detection with roadside LiDAR data under rainy and snowy conditions [J]. IEEE Intelligent Transportation Systems Magazine, 2020, 13(1): 197-209.
- [9] RUSU R B, COUSINS S. 3D is here: Point cloud library [C]. Proceedings of the IEEE international Conference on Robotics and Automation, 2011: 1-4.
- [10] CHARRON N, PHILLIPS S, WASLANDER S L. Denoising of lidar point clouds corrupted by snowfall [C]. Proceedings of the IEEE Conference on Computer and Robot Vision, 2018: 254-261.
- [11] 康国华,张琪,张晗,等. 基于点云中心的激光雷达与相机联合标定方法研究 [J]. 仪器仪表学报, 2019, 40(12): 118-126.
- KANG G H, ZHANG Q, ZHANG H, et al. Joint calibration of camera and lidar based on point cloud center [J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 118-126.
- [12] 冯明驰,高小倩,汪静姝,等. 基于立体视觉与激光雷达的车辆目标外形位置融合算法研究 [J]. 仪器仪表学报, 2021, 42(10): 210-220.
- FENG M CH, GAO X Q, WANG J SH, et al. Research on the fusion algorithm of vehicle object shape-position based on stereo vision and lidar [J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 210-220.
- [13] 朱玲嬿,常建华,李红旭,等. 改进的激光雷达回波信号去噪方法 [J]. 电子测量与仪器学报, 2017, 31(10): 1608-1613.
- ZHU L Y, CHANG J H, LI H X, et al. Improved denoising method of lidar echo signal [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(10): 1608-1613.
- [14] QI C R, SU H, MO K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 652-660.
- [15] QI C R, YI L, SU H, et al. Pointnet ++: Deep hierarchical feature learning on point sets in a metric space [C]. Proceedings of the Advances in Neural Information Processing Systems, 2017: 5100-5109.
- [16] ZHOU Y, TUZEL O. VoxelNet: End-to-end learning for point cloud based 3D object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4490-4499.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Proceedings of the 14th European Conference on Computer Vision, Amsterdam, Springer International Publishing, 2016, 11-14 (October): 21-37.
- [18] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.

- [19] YAN Y, MAO Y, LI B. Second: Sparsely embedded convolutional detection [J]. Sensors, 2018, 18(10): 3337.
- [20] YANG B, LUO W, URTASUN R. Pixor: Real-time 3d object detection from point clouds [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7652-7660.
- [21] LANG A H, VORA S, CAESAR H, et al. Pointpillars: Fast encoders for object detection from point clouds [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 12697-12705.
- [22] SHI S, WANG X, LI H. PointRCNN: 3D object proposal generation and detection from point cloud [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 770-779.
- [23] SHI S, GUO C, JIANG L, et al. PV-RCNN: Point-voxel feature set abstraction for 3D object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10529-10538.
- [24] YANG Z, SUN Y, LIU S, et al. 3DSSD: Point-based 3D single stage object detector [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11040-11048.
- [25] OGUCHI T. Electromagnetic wave propagation and scattering in rain and other hydrometeors [C]. Proceedings of the IEEE, 1983, 71(9): 1029-1078.
- [26] HAHNER M, SAKARIDIS C, BIJELIC M, et al. LiDAR snowfall simulation for robust 3d object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 16364-16374.

作者简介



陈熙源(通信作者),1998年毕业于东南大学获得博士学位,现为东南大学教授,主要研究方向为激光雷达环境感知、惯性技术、软件接收机及组合导航。

E-mail: chxiyuan@seu.edu.cn

Chen Xiyuan (Corresponding author) received his Ph. D. degree from Southeast University (SEU) in 1998. He is currently a professor at SEU. His main research interests include lidar environmental perception, inertial technologies, software defined receiver and integrated navigation.



戈明朋,2021年毕业于安徽大学获得学士学位,现为东南大学硕士研究生,主要研究方向为激光雷达多目标检测与跟踪。

E-mail: 220213599@seu.edu.cn

Ge Mingming received his B. Sc. degree from Anhui University. He is currently a master student at Southeast University. His main research interests include lidar multi target detection and tracking.



姚志婷,2019年毕业于华东理工大学获得学士学位,现为东南大学博士研究生,主要研究方向为态势感知与传感器数据融合。

E-mail: yaozhiting@seu.edu.cn

Yao Zhiting received her B. Sc. degree from East China University of Science and Technology in 2019. She is currently a Ph. D. candidate at Southeast University. Her main research interests include multi-object tracking and sensor fusion.



周云川,2021年于北京交通大学获得学士学位,现为东南大学硕士研究生,主要研究方向为基于卡尔曼滤波、因子图优化的移动机器人多源组合导航。

E-mail: 956457643@qq.com

Zhou Yunchuan received his B. Sc. degree from Beijing Jiaotong University in 2021. He is currently a master student at Southeast University. His main research interests include multi-source integrated navigation of mobile robot based on Kalman filter and factor graph optimization.