

点云数据去噪的自适应联合滤波方法

曲大义, 韦良帅, 王可栋, 张智, 李文杰

(青岛理工大学机械与汽车工程学院, 山东 青岛 266525)

摘要: 针对恶劣天气条件下激光雷达采集的点云数据噪声严重、传统去噪方法精度低的问题, 提出一种基于局部特征与空间距离关系的自适应联合滤波方法。首先依据雪花噪声的特征设定强度阈值, 用于区分潜在的噪声点与有效点, 随后利用对数正态分布对雪花噪声的分布规律进行拟合, 将雪花噪声区域分为3种类型, 并结合不同区域噪声点云的特征差异, 分别设计对应的去噪策略。其中, 高密度区域采用改进后的DSOR进行去噪, 将点的强度信息引入阈值计算, 使算法能够综合考虑空间结构与强度特性; 在低密度区域, 算法根据点的局部几何特征和邻域密度信息设定动态阈值, 对孤立噪声点进行筛选与去除, 最后将高、低密度区域滤波后的点云与无噪声区域的点云进行融合, 得到完整的去噪点云。实验结果表明, 自适应联合滤波方法在精确率较DSOR提升5.16%的情况下, 召回率提升约3.29%, 有效减少了噪声点的漏检情况, 与引入反射强度的DDIOR相比, 该方法在保持较高精确率的同时进一步增强了噪声点识别能力, 能够在不同交通场景中实现更稳定的去噪效果。

关键词: 恶劣天气; 点云去噪; 自适应联合滤波; DSOR; 反射强度

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202534

An adaptive joint filtering method for point cloud denoising

QU Dayi, WEI Liangshuai, WANG Kedong, ZHANG Zhi, LI Wenjie

School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266525, China

Abstract: To address the problem of severe noise in LiDAR point cloud data collected under adverse weather conditions and the low accuracy of traditional denoising methods, an adaptive joint filtering method based on local features and spatial distance relationships is proposed. First, an intensity threshold is set based on the characteristics of snowflake noise to distinguish potential noise points from valid points. Then, the spatial distribution of snowflake noise is modeled using a log-normal distribution, dividing the noise regions into three types. Corresponding denoising strategies are designed according to the characteristics of noise points in different regions. In high-density regions, an improved DSOR algorithm is applied, incorporating the intensity information of points into the threshold calculation, enabling the algorithm to consider both spatial structure and intensity features. In low-density regions, dynamic thresholds are set based on the local geometric features and neighborhood density of points to filter and remove isolated noise points. Finally, the filtered point clouds from high- and low-density regions are merged with the point cloud from noise-free regions to obtain the complete denoised point cloud. Experimental results show that the adaptive joint filtering method improves precision by 5.16% and recall by approximately 3.29% compared to DSOR, thereby effectively reducing the number of missed noise points. Compared with DDIOR, which also incorporates intensity information, the proposed method maintains a high precision while further enhancing the ability to identify noise points, achieving more stable denoising performance across different traffic scenarios.

Key words: adverse weather, point cloud denoising, adaptive joint filtering, DSOR, intensity

收稿日期: 2025-04-25; 修回日期: 2025-09-03

通信作者: 韦良帅, weiliangshuai1999@163.com

基金项目: 国家自然科学基金项目 (No.52272311)

Foundation Item: The National Natural Science Foundation of China (No.52272311)

0 引言

随着新能源汽车的智能化、网联化进程加速,自动驾驶技术已成为产业竞争的核心,激光雷达凭借其高精度、三维环境感知等优势,逐渐成为自动驾驶技术中的重要传感器之一^[1],也成为无人驾驶解决方案中的关键组成部分^[2],它通过扫描周围环境生成三维点云数据以描述车辆周边环境^[3]。然而在实际应用中,点云采集易受多种因素影响,雨雪等恶劣天气的干扰、车辆行驶中的抖动等都会导致点云中大量离群噪声、漂移噪声^[4],直接影响环境感知精度及后续环境规划的安全性及合理性。如何在真实驾驶环境中有效滤除点云噪声是当前智能驾驶中的一项重要任务。

近年来,国内外众多学者针对点云去噪进行了深入研究,提出了多种点云去噪算法。其中统计离群点去除(statistical outlier removal, SOR)滤波器^[5]和半径离群点去除(radius outlier removal, ROR)滤波器^[6]是最经典的滤波方法。在此基础上众多优化算法被提出。贾朝阳等^[7]提出一种基于距离阈值和密度区分的点云去噪算法,使用比例因子 ω 调整统计滤波阈值表达式,随后将点云大密度点进行体素滤波后与小密度点整合为最终的点云模型,在去噪的同时有效保持点云模型的局部特征。郑天洋等^[8]提出一种基于法向量方向信息特征分类的去噪方法,首先通过统计滤波与半径滤波联合去除大尺度噪声,随后通过法向直方图的峰值对点云进行区域划分,针对不同区域分别采用双边滤波和自适应引导滤波平滑小尺度噪声,既能有效去除点云模型的多尺度噪声,也能较好地保持模型的特征细节。Ge等^[9]提出一种基于改进DBSCAN(density-based spatial clustering of applications with noise)的多尺度点云去噪算法,首先通过统计滤波过滤孤立离群点,随后使用DBSCAN将点云分为正常簇、疑似簇、异常簇,并使用距离共识评估法对疑似簇进行精细判定,保持数据关键特征和模型敏感度。Zhao等^[10]提出一种自适应DBSCAN点云去噪方法,通过动态调整邻域半径和最小邻域点,实现高精度去噪和关键信息保留。Cattai等^[11]提出一种基于视觉驱动的点云去噪算法,通过多尺度各向异性谐波滤波来分析局部几何和纹理信息,采用自适应邻域与迭代更新策略,有效抑制噪声,同时保留边缘细节,提升重建精度。赵涵等^[12]提出一种基于混合滤波的

点云去噪算法,使用KD-Tree加快邻域搜索速度,另外改进DBSCAN算法中邻域半径的设定方式,通过分析点云欧氏距离分布,选取概率最大区间的中值作为邻域半径,增强了密度聚类去噪的自适应能力。

以上这类方法未针对交通场景雪花点云的近密远疏分布差异、随机噪声无规律附着等特性进行优化,易丢失交通目标特征或因计算复杂无法实时去噪。为解决上述问题,Charron等^[13]提出了基于距离的动态半径离群点去除(dynamic radius outlier removal, DROR)滤波器,通过动态调整被测点距离对应的邻域搜索半径,克服传统ROR远距离精度下降的问题,但逐点距离计算会导致其速度较慢;Kurup等^[14]提出用动态统计离群点去除(dynamic statistical outlier removal, DSOR)滤波器作为SOR的扩展方法,使用KD树加载点云并计算每个点与其 k 个最近邻点之间的平均距离以及距离偏差,以此获取全局阈值后与点云距离相关联,动态地生成不同区域的滤波阈值;Park等^[15]首次提出利用强度数据去除噪声的低强度噪声去除(low-intensity outlier removal, LIOR)滤波器,通过强度阈值初步筛选结合RIS半径内点保存二次验证两步流程,实现了比DROR更快的处理速度,还提升了去噪精度;Wang等^[16]通过分析雪天场景下LiDAR点云的特征分布,发现雪噪声点具有近距离、高密度、低强度、随距离增加快速衰减的特点,据此提出动态距离-强度离群点去除(dynamic distance-intensity outlier removal, DDIOR)滤波器,通过整合点云距离与强度特征计算动态阈值,在高效去噪的同时,保留较完整的环境细节。

因此本文根据噪声点云的分布特征、强度特征,将点云划分为不同的密度区域,高密度区域引入基于强度信息优化的DSOR算法,通过自适应动态阈值进行滤波;在低密度区域,则采用结合曲率和局部密度的动态阈值方法进行去噪,随后将高密度区域、低密度区域去噪后的点云与原本筛选的无噪声点云合并,得到最终滤波后的点云。

1 雪天点云噪声特征分析

1.1 数据可视化分析

为了客观分析雪天场景下的噪声点云特征,数据采用发布于2021年的WADS数据集。该数据集与前文提及的DSOR源自同一研究,共收集超26 TB

的多模态数据，其中包含约7 GB的激光雷达点云数据，并按Semantic KITTI的格式进行逐点语义标注，新增降雪（falling snow）、积雪（accumulated snow）两个类别，共有19个可用序列集。与其他数据集相比，WADS数据集提供了精细的逐点标注，能够充分反映出环境细节，为后续的点云数据分析、目标检测、语义分割等任务提供了针对性数据^[17]。本文选取序列11~18、20、22~24、26及28共计14个序列，用于分析与可视化部分的研究；30、34~37共5个序列用于实验验证。

为了直观呈现数据特征，任取序列13、序列15的一帧点云数据按不同类别进行可视化，结果如图1所示。从图1可知，雪花噪声点云（黑色点）多集中于激光雷达传感器附近，且呈现高密度分布特性。从14个可用序列集中各抽取一帧，绘制点云数量与点到传感器距离的关系图，如图2所示，观察发现，点云数量随距离的增加呈现先急剧上升、后快速衰减的特点，符合激光雷达近密远疏的扫描特性，同时可以观察到雪花噪声集中分布在距离传感器50 m以内的范围。WADS数据集的强度区间值为0~255，将每10个强度值作为一个子区间，统计各子区间噪声点数量及占比，结果见表1。从表1可知，反射强度值在0~10时点云数量占比最大，约占总噪声点云的73.543%，反射强度值小于50的数量约占总噪声比例的99.823%。随后将激光雷达反射强度归一化后与距离进行统计，结果如图3所示，根据噪声点的分布特征可以发现，雪花对激光信号的反射能力较弱，大部分噪声信号强度低于0.3，且当距离超过一定范围后，雪花噪声点几乎消失。统计结果验证了Wang等提出的雪花噪声具有高密度、低强度、近距离与随距离增加快速衰减的特性。

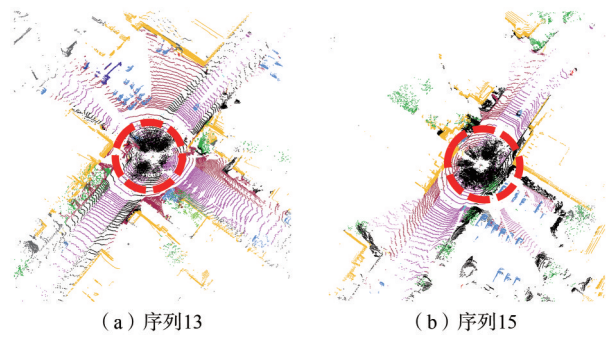


图1 WADS数据集可视化

表1 不同强度区间的噪声点云数量

强度区间	[0,10)	[10,20)	[20,30)	[30,40)	[40,50)	[50,255)
噪声数量	534 456	143 980	38 793	7 286	922	1 291
占比	73.543%	19.812%	5.338%	1.003%	0.127%	0.178%

1.2 雪天点云噪声的分布拟合

对雪天点云噪声的统计与分析明确了雪天点云噪声具有高密度、低强度、近距离与快速衰减的特性，但单纯的统计结果难以精准描述噪声分布的连续概率特性。因此本文将噪声的分布特征转化为可解析的数学模型，根据雪花噪声距离分布的非负性、右偏性，采用3种典型概率分布模型（伽马分布^[18]、对数正态分布^[19]、核密度估计^[20]）进行拟合。3种模型的概率密度函数表达式如下：

$$f(x) = \frac{x^{\alpha-1} e^{-\frac{x}{\theta}}}{\theta^{\alpha} \Gamma(\alpha)} \quad (x > 0) \quad (1)$$

$$f(x) = \frac{1}{xs\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2s^2}} \quad (x > 0) \quad (2)$$

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (3)$$

其中， α 和 θ 分别表示伽马分布的形状参数和尺度参数， μ 和 s 分别表示对数正态分布的位置参数和

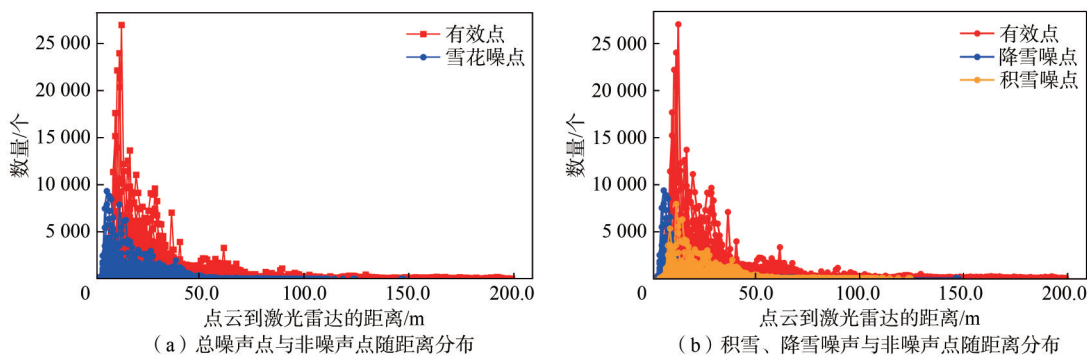


图2 距离与点云数量关系

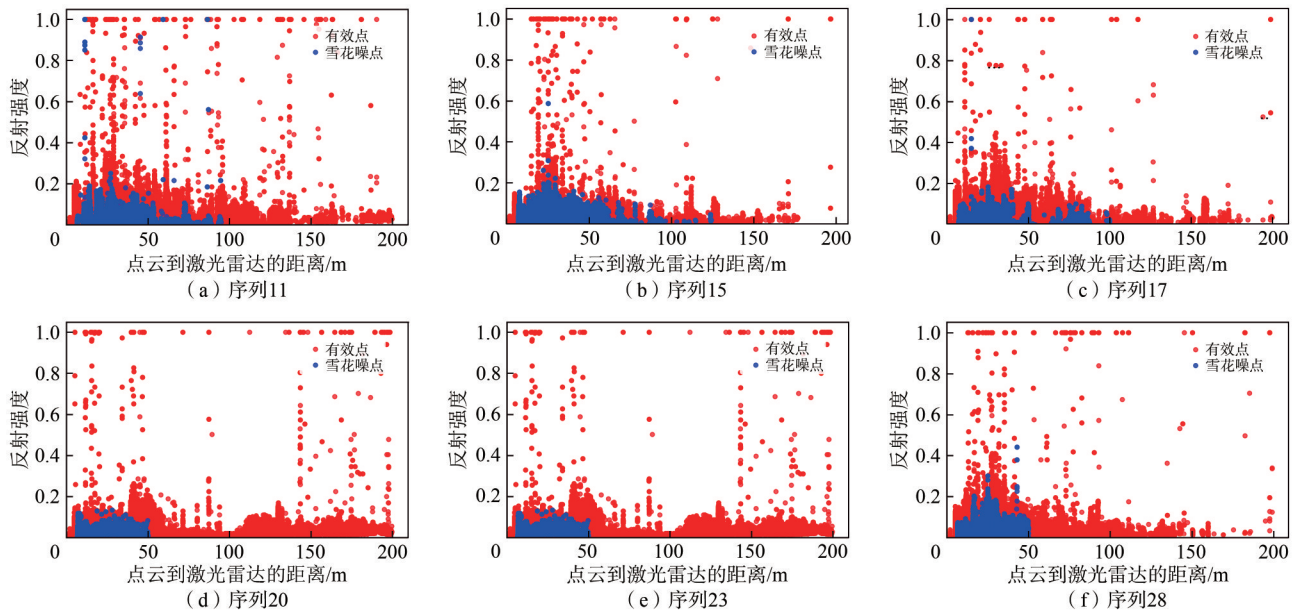


图3 距离与反射强度关系

尺度参数， Γ 表示伽马函数， n 表示样本量， h 表示带宽， K 表示高斯核函数。为了验证上述3种模型对雪天点云噪声距离分布的刻画能力，笔者采用决定系数 R^2 量化评估拟合优度，拟合参数与结果如表2和图4所示。

表2 各分布拟合参数及结果

方法	形状参数	尺度参数	决定系数
伽马分布	2.571 866	4.986 926	0.844
对数正态分布	0.683 063	11.318 051	0.911
核密度估计	—	—	0.729




图4 各分布拟合结果


根据表2与图4的结果，伽马分布与对数正态分布对噪声的拟合效果较优，能够很好地刻画噪声随距离的分布，对数正态分布的决定系数为0.911，说明其在整体分布拟合上更贴近噪声数据的真实概率特征，核密度估计虽然无须预设参数，但其决定

系数仅为0.729，与另外两个分布相比拟合效果较差，故本文采用对数正态分布进行噪声随距离分布的建模与分析。


为了平衡计算效率与精度，同时对距离阈值进行量化界定，引入双显著性水平0.05、0.01，结合雪花噪声点距离分布的对数正态拟合结果，通过求解不同显著性水平下的概率边界条件，将空间划分为3个区域（高密度区域、低密度区域、无噪声区域），对应边界阈值分别为34.81 m、55.45 m，划分结果如图5所示，距离小于绿色边界线的区域定义为高密度区域，距离在绿色与黄色线之间的定义为低密度区域，距离大于黄色线的区域则定义为无噪声区域。结合划分结果可以发现，高密度区域噪声点云呈现高聚集性的特点，绝大部分噪声点云分布于此区域内；低密度区域噪声点云分布离散性特征逐渐显著，呈现稀疏性、孤立性特征。由于远距离区域的雪花噪声点在0.01显著性水平下出现的概率已低至可忽略，因此将距离大于55.45 m的区域视为无噪声点区域，不对其进行滤波处理。

2 自适应联合滤波方法

基于雪花噪声点距离分布的统计特性与双显著性水平概率边界分析，已通过0.05、0.01两个显著性水平的概率边界条件，将空间划分为3个特征区域。距离小于34.81 m的归为近距离高密度区域，该区域内雪花噪声点出现的概率高，点云噪声分布密集；



(a) 总数量-距离区域划分



(b) 序列11实际场景中区域划分

图5 区域划分结果

距离在 34.81~55.45 m 的定义为低密度区域，该区域噪声出现的概率明显降低，点云噪声分布离散性较显著；距离大于 55.45 m 的区域定义为无噪声区域，该区域内噪声数量占比不大，对去噪结果影响较小。

针对不同区域的噪声分布特性，为了实现精准且高效的滤波处理，本文提出自适应联合滤波方法，在高密度与低密度区域中使用不同的滤波方法，以提升复杂噪声场景下的整体滤波效果。在数据预处理阶段，算法将计算各点距传感器的欧氏距离，按距离划分各点的区域归属。设定统一的滤波强度阈值，点云反射强度高于预设的强度阈值则直接作为有效点保留，反射强度低于强度阈值的点作为后续滤波的输入点。根据图3的结果，本文将强度阈值设为0.3，以序列11中一帧为例绘制划分结果，如图6所示，其中紫色线下方为待滤波点云，将强度高于紫色线的点云视为有效点，不对其进行滤波处理。

2.1 高密度区域去噪

根据图5(a)、图5(b)区域的划分结果可见，高密度区域噪声点云呈现出高密度、强聚集的特征，该区域内雪花噪声点出现的频率高，且多以密集簇状形态分布，与有效点云的空间重叠度高，由于距离传感器较近，点云整体密度大，噪声点与非噪声点的局部空间距离差异较小。

DSOR 滤波器是一种基于统计的点云去噪方




图6 序列11强度阈值划分结果

法，该方法首先通过KD树对每个点进行k近邻搜索以获取平均距离，基于这些平均距离的均值 μ_1 和标准差 σ 计算全局阈值 T_g ，再结合点到传感器的距离与预设的距离乘法因子得到动态阈值 T_d ，通过比较点的平均距离与动态阈值来判定并移除雪噪声。动态阈值 T_d 计算式如下：

$$T_d = T_g \cdot r \cdot \text{distance} \quad (4)$$

其中， $T_g = \mu_1 + (\sigma \cdot \text{constant})$ ， r 为预设的距离乘法因子， distance 为点到雷达传感器的距离。然而DSOR的滤波阈值仅依赖几何特征来判断噪声，未充分利用激光雷达点的反射强度信息。为了提升去噪效果，本文将反射强度引入动态阈值的计算中，使阈值不仅依赖空间邻域特征，还考虑点的强度差

异, 改进后的滤波阈值计算式如下:

$$T_{dl} = I_n \cdot T_g \cdot r \cdot \text{distance} \quad (5)$$

其中, $I_n = 1 - i_n$ 为强度补偿系数, i_n 表示各点归一化后的强度值。通过增加 I_n 项, 阈值能够随点的强度和距离自适应调整, 充分利用点云的强度信息, 使 DSOR 算法在高密度区域更有效地区分有效点和噪声点。

2.2 低密度区域去噪

根据图5所示的区域划分结果, 低密度区域的噪声点数量相比高密度区域显著减少, 空间分布呈现离散簇、弱聚合特征, 噪声点不再形成连续密集簇, 以小规模、相对分散的簇团形式存在, 这些簇团与有效点云局部重叠度低, 相邻噪声簇间距大于高密度区域, 部分噪声点以孤立的离散点形式存在。在低密度区域自适应联合滤波方法使用局部密度、曲率融合的滤波方法, 远处噪声点多以表面曲率高、局部孤立性强等特点存在。基于这些特性, 算法通过递进式判断进行滤波, 首先利用预设的强度阈值筛选出待滤波点, 随后算法通过构建任意点的协方差矩阵 C 计算得到3个特征值 $\lambda_0 \leq \lambda_1 \leq \lambda_2$, 曲率则定义为最小特征值与特征值总和的比值。协方差矩阵 C 与曲率 κ_i 的计算式如下:

$$C = \frac{1}{k} \sum_{j=1}^k (\mathbf{P}_j - \mathbf{c})(\mathbf{P}_j - \mathbf{c})^T \quad (6)$$

$$\kappa_i = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2 + \varepsilon} \quad (7)$$

其中, \mathbf{P}_j 表示 P_i 点的 k 近邻点集, \mathbf{c} 表示邻域的均值向量, ε 表示极小的常数。有效目标连续表面邻域点离散性主要体现在最大特征值 λ_2 方向, 最小特征值 λ_0 极小, 因而曲率也极小, 远距离噪声点因邻域分布散乱 λ_0 较大, 导致曲率值偏高。

单一的曲率特征仅能反映物体的几何形态, 通过引入局部密度特征使算法在面对远距离低密度点云时, 具备对空间分布特性的感知能力, 算法将局部密度 ρ_i 定义如下:

$$\rho_i = \frac{1}{\bar{d}_i + \varepsilon} \quad (8)$$

其中, \bar{d}_i 表示点 P_i 与 k 个近邻点欧氏距离的均值。为适配噪声点云局部密度随距离增加而稀疏化的特性, 将低密度区域内所有点的局部密度均值作为基础阈值, 引入距离调节机制, 构建动态变化的密度阈值模型, 动态密度阈值定义如下:

$$T_\rho = \beta + \delta \cdot \text{distance} \quad (9)$$

其中, β 为区域内所有点的局部密度均值, δ 为距离调节因子。在获得低密度区域点的曲率与局部密度后, 将曲率大于曲率阈值且局部密度小于动态密度阈值的点判定为噪声点, 保留不满足该双重条件的点作为低密度区域的有效点。

将数据预处理阶段保留的点云与经过高、低密度区域过滤后得到的点云进行融合拼接, 形成最终的去噪点云结果。

3 实验验证与分析

为了验证算法的有效性, 实验采用 WADS 公开数据集 30、34~37 共 5 个序列进行验证, 每个序列随机抽取 10 帧作为验证对象, 平均每帧点云约含 21 万个扫描点, 其中雪花噪点约 9.5 万个。实验所用处理器为 Intel Core i5-8300h、RAM 为 16 GB、操作系统为 Windows 11。

3.1 评价指标

为了评估算法在去噪方面的效果, 本文采用去噪精确率、去噪召回率进行定量的评价比较, 各评价指标计算式如下:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (11)$$

其中, TP 表示被正确地识别为噪声并去除的点数, FP 表示实际为非噪声但被错误地去除的点数, TN 表示实际为非噪声且被正确保留的点数, FN 表示实际为噪声但被错误地保留的点数。

3.2 实验结果与分析

实验首先进行了定性分析, 将所选取的 6 种滤波器与自适应联合滤波方法进行去噪可视化分析, 各方法绘图所用参数, 见表 3, 将去噪结果可视化 (如图 7 所示), 其中黑色点对应表示标记的雪花噪声, 分布较为杂乱无章的点多属于新增降雪噪声, 分布比较规则的点多属于积雪噪声。观察发现固定阈值的 ROR 和 SOR 方法, 对远距离有效点的保留效果较差, 丢失了大部分的环境点, 且对近处的密集噪声点云也未能有效去除, 其余算法对空中的雪花有较好的滤除作用, 但对积雪的过滤存在不足。分析其原因可能为积雪通常附着在地面或物体表面, 其点云特征与周围环境点相似, 使算法难以精确区分积雪与环境点, 从而造成对积雪的过滤效果差, 或将环境点一并去除, 破坏环境的完整性。

表3 各滤波方法所用参数

滤波方法	超参数
ROR	radius=0.1 min_neighbors=3
SOR	nb_neighbors=5 std_ratio=0.01
DROR	radius_multiplier=3 azimuth_angle_deg=0.08 min_neighbors=3 min_search_radius=0.04
DSOR	k-nearest neighbors=5 s=0.01 r=0.1
DDIOR	k-nearest neighbors=5
LIDSOR ^[21]	k-nearest neighbors=30 s=0.5 r=0.05 i_threshold=30 d_threshold=55.45
自适应联合滤波方法	k=5 constant=0.01 r=0.1 curvature_threshold=0.005 dynamic_density_b=0.05

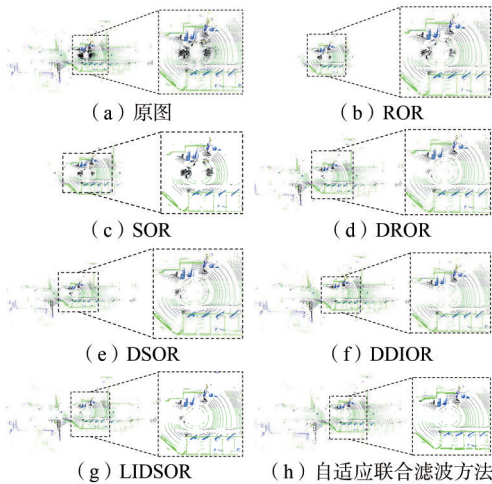


图7 各滤波算法的去噪效果可视化对比

为了客观分析算法在不同交通场景下的去噪性能，实验除从WADS数据集的5个序列中各选取10帧点云外，又以KITTI公开数据集^[22]为基础，通过人工添加噪声的方式额外构建了20帧实验点云，KITTI添加噪声后如图8所示，其中蓝色点表示添加的噪声点。两类数据共计70帧点云构成实验测试数据集，将各帧所得结果取均值后，统计结果见表4。

与图7展示的结果类似，ROR与SOR采用固定滤波阈值，故在复杂的交通场景中展现出明显的




图8 KITTI数据集点云人工噪声添加效果

表4 各算法评价指标

方法	Precision	Recall
ROR	26.18%	74.48%
SOR	23.93%	68.27%
DROR	56.84%	65.57%
DSOR	58.92%	59.68%
DDIOR	62.67%	62.59%
LIDSOR	64.93%	60.63%
自适应联合滤波	64.08%	62.97%

局限性，过严的阈值会导致其删除大量的有效点，而过松的阈值会导致滤波程度不足，残留过多的噪声，通过调整阈值勉强达到理想召回率，滤波阈值需设定得较为严格，使精确率大幅下降，难以在噪声滤除和保留交通环境点之间实现平衡。表4的结果表明，ROR与SOR的召回率分别为74.48%和68.27%，但精确率仅为26.18%和23.93%，两个算法在交通场景去噪中误检严重，难以在噪声滤除与交通环境点保留之间取得平衡。DROR召回率为65.57%，虽低于ROR与SOR，但精确率显著提升至56.84%，表明其在减少误检方面更具优势。DSOR相较于DROR在精确率和召回率上均保持了较为均衡的表现，分别为58.92%和59.68%。DDIOR和LIDSOR阈值计算中引入了点云的强度信息，利用强度与空间分布的联合特征进行判别，从而显著提升了精确率，分别达到62.67%和64.93%，召回率相较于DSOR均有所提升。与上述方法相比，自适应联合滤波在精确率上达到64.08%，略高于DDIOR，并较DSOR提升约5.16%；召回率相较于DSOR提高3.29%，相较于DDIOR提高0.38%，相较于LIDSOR提高2.34%。综合来看，与其他方法相比，自适应联合滤波方法在精确率与召回率之间实现了更优的平衡，能够有效减少漏检噪声点的情况。

4 结束语

本文提出了一种自适应联合滤波的点云去噪算

法, 首先根据雪花反射强度特征设定强度阈值, 随后采用对数正态分布对雪花噪声的空间分布规律进行拟合, 并依据显著性水平将点云划分为高密度区域、低密度区域。本文针对不同区域的特性设计了相应的滤波策略: 在高密度区域, 采用改进后的DSOR算法, 引入强度信息, 使算法能够综合考虑空间结构与强度特性; 在低密度区域, 利用点的局部几何特征和邻域密度设定动态阈值, 对孤立噪声进行筛选和去除。实验结果表明, 与DSOR相比, 自适应联合滤波在精确率提升5.16%的情况下, 召回率提升约3.29%, 有效减少了漏检噪声点, 也表明该方法在不同场景下能够较好地保持点云结构的完整性。

参考文献:

- [1] 程川, 宋春华, 王鹏. 车载激光雷达发展研究综述[J]. 装备制造技术, 2022(5): 247-251.
CHENG C, SONG C H, WANG P. Review on the development of vehicle-borne lidar[J]. Equipment Manufacturing Technology, 2022(5): 247-251.
- [2] 田永林, 沈宇, 李强, 等. 平行点云: 虚实互动的点云生成与三维模型进化方法[J]. 自动化学报, 2020, 46(12): 2572-2582.
TIAN Y L, SHEN Y, LI Q, et al. Parallel point clouds: point clouds generation and 3D model evolution via virtual-real interaction[J]. Acta Automatica Sinica, 2020, 46(12): 2572-2582.
- [3] 黄哲, 王永才, 李德英. 3D目标检测方法研究综述[J]. 智能科学与技术学报, 2023, 5(1): 7-31.
HUANG Z, WANG Y C, LI D Y. A survey of 3D object detection algorithms[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(1): 7-31.
- [4] BIJELIC M, GRUBER T, MANNAN F, et al. Seeing through fog without seeing fog: deep multimodal sensor fusion in unseen adverse weather[C]// Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 11679-11689.
- [5] 肖俊, 石光田. 三维点云去噪技术[J]. 中国科学院大学学报, 2023, 40(5): 577-595.
XIAO J, SHI G T. Three-dimensional point cloud denoising[J]. Journal of University of Chinese Academy of Sciences, 2023, 40(5): 577-595.
- [6] 李仁忠, 杨曼, 冉媛, 等. 基于方法库的点云去噪与精简算法[J]. 激光与光电子学进展, 2018, 55(1): 251-257.
LI R Z, YANG M, RAN Y, et al. Point cloud denoising and simplification algorithm based on method library[J]. Laser & Optoelectronics Progress, 2018, 55(1): 251-257.
- [7] 贾朝阳, 陈岳坪, 苏宇. 基于距离阈值和密度区分改进的点云去噪算法[J]. 工具技术, 2024, 58(10): 147-154.
JIA Z Y, CHEN Y P, SU Y. Point cloud denoising algorithm based on distance threshold and density distinction[J]. Tool Engineering, 2024, 58(10): 147-154.
- [8] 郑天洋, 马斌. 多尺度点云噪声的平滑去噪方法[J]. 应用激光, 2024, 44(12): 148-157.
ZHENG T Y, MA B. Smooth denoising method for multi-scale point cloud noise[J]. Applied Laser, 2024, 44(12): 148-157.
- [9] GE C P, ZHAO D, WANG R, et al. Section point cloud denoising method based on enhanced DBSCAN and distance consensus evaluation[J]. Journal of System Simulation, 2024, 36(8): 1800-1809.
- [10] ZHAO Z, ZHOU W L, LIANG D H, et al. Denoising method based on improved DBSCAN for lidar point cloud[J]. IEEE Access, 2024, 12: 137656-137666.
- [11] CATTAI T, DELFINO A, SCARANO G, et al. VIPDA: a visually driven point cloud denoising algorithm based on anisotropic point cloud filtering[J]. Frontiers in Signal Processing, 2022, 2: 842570.
- [12] 赵涵, 刘永生, 赵德鹏, 等. 基于混合滤波的点云去噪算法研究[J]. 应用激光, 2023, 43(9): 147-155.
ZHAO H, LIU Y S, ZHAO D P, et al. Research on point cloud denoising algorithm based on hybrid filtering[J]. Applied Laser, 2023, 43(9): 147-155.
- [13] CHARRON N, PHILLIPS S, WASLANDER S L. De-noising of lidar point clouds corrupted by snowfall[C]//Proceedings of the 2018 15th Conference on Computer and Robot Vision (CRV). Piscataway: IEEE Press, 2018: 254-261.
- [14] KURUP A, BOS J. Dsor: a scalable statistical filter for removing falling snow from lidar point clouds in severe winter weather[EB]. arXiv preprint, 2021, arXiv:2109.07078.
- [15] PARK J I, PARK J, KIM K S. Fast and accurate desnowing algorithm for LiDAR point clouds[J]. IEEE Access, 2020, 8: 160202-160212.
- [16] WANG W Q, YOU X, CHEN L Y, et al. A scalable and accurate desnowing algorithm for LiDAR point clouds in winter[J]. Remote Sensing, 2022, 14(6): 1468.
- [17] 武雨田, 李擎, 孙文蔚, 等. 复杂天气下车载激光点云目标检测方法综述[J]. 工程科学学报, 2025, 47(5): 1081-1093.
WU Y T, LI Q, SUN W W, et al. Overview of object detection methods based on LiDAR point cloud under adverse weather conditions[J]. Chinese Journal of Engineering, 2025, 47(5): 1081-1093.
- [18] RONNBACK S, WERNERSSON A. On filtering of laser range data in snowfall[C]//Proceedings of the 2008 4th International IEEE Conference Intelligent Systems. Piscataway: IEEE Press, 2008: 17-33-17-39.
- [19] SIANO D B. The log-normal distribution function[J]. Journal of Chemical Education, 1972, 49(11): 755.
- [20] GRAMACKI A. Kernel density estimation[M]//Nonparametric Kernel Density Estimation and Its Computational Aspects. Cham: Springer International Publishing, 2017: 25-62.
- [21] HUANG H, YAN X, YANG J, et al. Lidsor: a filter for removing rain and snow noise points from lidar point clouds in rainy and snowy weather[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2023, XLVIII-1/W2-2023: 733-740.
- [22] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]//Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2012: 3354-3361.


[作者简介]



曲大义 (1973-), 男, 博士, 青岛理工大学机械与汽车工程学院教授, 主要研究方向为车路协同及安全控制。



韦良帅（1999-），男，青岛理工大学机械与汽车工程学院硕士生，主要研究方向为车辆感知技术。



张智（1999-），男，青岛理工大学机械与汽车工程学院硕士生，主要研究方向为运载系统动力学及协同控制。



王可栋（1986-），男，青岛理工大学机械与汽车工程学院博士生，主要研究方向为人机共驾理论及技术。



李文杰（2000-），男，青岛理工大学机械与汽车工程学院硕士生，主要研究方向为车辆行为建模。