极寒降雪环境中激光雷达-惯性测距的点云预处理优化*

赵化启[1] 王浩禹[1] 陈杰[1] 夏崇康[1] 李国晶[2]

（1.佳木斯大学信息电子技术学院，佳木斯 154007；2.佳木斯大学材料科学与工程学院，佳木斯 154007）

【摘要】针对极寒降雪环境下激光雷达同步定位与建图（SLAM）中，雪花散射、积雪遮挡导致的环境特征模糊对激光雷达点云的影响，基于LIO-SAM算法框架，在点云预处理部分采用动态半径异常值去除（DROR）滤波器消除因雪引起的噪声，同时保留环境特征的细节，为LIO-SAM算法后续的点云处理提供高质量点云数据。在CADC数据集上的验证结果表明：相较于LIO-SAM自带的滤波器，试验在雪天条件下采集的点云数据，在保持较高精度的同时，召回率超过91%，有效去除雪点噪声并保留了更多的环境特征。

主题词：激光雷达 极寒环境 雪花散射 LIO-SAM 滤波 DROR

中图分类号：TN958.98 **文献标志码：**A **DOI:** 10.19620/j.cnki.1000-3703.20250704

Optimization of Point Cloud Preprocessing for LiDAR-Inertial Ranging in Extreme Cold and Snowy Conditions

Zhao Huaqi[1], Wang Haoyu[1], Chen Jie[1], Xia Chongkang[1], Li Guojing[2]

（1. College of Information and Electronic Technology, Jiamusi University, Jiamusi 154007; 2. College of Materials Science and Engineering, Jiamusi University, Jiamusi 154007）

【**Abstract**】To address the impact of blurred environmental features caused by snow and ice coverage on LiDAR point clouds during real-time laser-based construction and Simultaneous Localization and Mapping (SLAM) in extremely cold environments, this paper employs the LIO-SAM algorithm framework. In the point cloud preprocessing stage, a Dynamic Radius Outlier Removal (DROR) filter is used to eliminate snow-induced noise while preserving the details of environmental features, thereby providing high-quality point cloud data for subsequent processing by the LIO-SAM algorithm. Validation results on the CADC dataset show that, compared to the filter built into LIO-SAM, the point cloud data collected under snowy conditions achieves a recall rate exceeding 91% while maintaining high accuracy. This approach effectively removes snow-induced noise while preserving more environmental features.

Key words: Light Detection and Ranging (LiDAR), Extreme cold weather, Snowflake scattering, LIO-SAM, Filtering, Dynamic Radius Outlier Removal (DROR)

【引用格式】赵化启，王浩禹，陈杰，等. 极寒降雪环境中激光雷达-惯性测距的点云预处理优化[J]. 汽车技术，2026(8): 30-36.

ZHAO H Q, WANG H Y, CHEN J, et al. Optimization of Point Cloud Preprocessing for LiDAR-Inertial Ranging in Extreme Cold and Snowy Conditions[J]. Automobile Technology, 2026(8): 30-36.

1 前言

自动驾驶技术是智能交通领域的重要研究方向，激光雷达同步定位与建图（Simultaneous Localization and Mapping，SLAM）技术是实现自动驾驶系统环境感知与高精度定位的关键。然而，在极寒降雪环境中，雪花散射、积雪遮挡及低温等因素会导致激光雷达点云中出现大量噪声和特征退化，严重影响SLAM系统的定位精度

*基金项目：黑龙江省重点研发计划（创新基地）项目（JD24A014）；黑龙江省自然科学基金资助项目（LH2022E114）；2024年度黑龙江省高等学校基本科研业务费项目（2024-KYYWF-0553）；2024年度黑龙江省高等教育教学改革研究一般项目（SJGYY2024227）；佳木斯市市级科技计划创新激励类项目（GY2023JL0002）；佳木斯大学“东极”学术团队项目（DJXSTD202417）；佳木斯大学横向项目（JMSUHXXM2024082101）。

通信作者：李国晶（1979—），副教授，主要研究方向为金属材料，li_guojing@126.com。

与建图质量。

在激光SLAM定位建图方面，Zhang等[1]提出了激光雷达里程计与建图（Lidar Odometry and Mapping，LOAM）算法，通过提取边缘点和平面点，实现高精度激光里程计估计，在保证定位精度的同时兼顾了实时性。但该方法未融合惯性测量单元(Inertial Measurement Unit，IMU）信息，在快速运动或复杂环境下易产生累计误差。Shan等[2]基于LOAM方法引入地面分割和轻量化设计，提高了计算效率，并通过回环检测进一步减小累计误差，但其采用的松耦合融合方式对IMU信息利用率不足，在复杂运动场景中的鲁棒性仍需提升。

为进一步提高定位精度，Shan等[3]提出了带平滑和建图功能的激光雷达-惯性测距（Lidar-Inertial Odometry with Smoothing and Mapping，LIO-SAM）算法，将LiDAR、IMU和全球定位系统（Global Positioning System，GPS）信息进行紧耦合融合，采用因子图优化，实现高精度状态估计，在大规模场景建图和快速运动环境下取得良好的定位性能。然而，上述研究主要针对常规天气条件开展，在极寒降雪环境下仍存在一定局限性。

由于降雪过程中产生的大量雪花噪声严重干扰激光雷达回波信息，导致点云中出现大量离群点和伪特征。同时，远距离目标点云密度降低，传统固定参数滤波算法容易误删有效环境特征，从而降低后续点云匹配和地图构建精度。因此，在保证有效环境特征完整性的前提下，实现雪花噪声的高效去除，是提升极寒环境下LIO-SAM系统性能的关键问题。为此，本文基于LIO-SAM框架，在点云预处理阶段引入动态半径异常值去除（Dynamic Radius Outlier Removal，DROR）滤波算法，通过动态调整搜索半径实现雪花噪声去除，同时尽可能保留环境有效特征，并基于CADC（Canadian Adverse Driving Conditions）数据集[4]验证本文方案对极寒环境下点云质量及SLAM建图性能的改善效果。

2　极寒环境降雪的点云特征分析

极寒环境下，空气密度增大加剧激光散射与衰减，在降雪过程中雪花的遮挡、散射及随机分布特性，共同导致点云密度降低、空间分布离散且出现空洞与不连续区域，在偏离常规规则分布模式的同时，极寒环境改变物体表面物理性质、雪花独特的反射吸收特性及多层散射效应，使点云反射强度呈现增强或波动的明显变化，从而增加目标识别与分类难度。降雪形成的不均匀积雪层会改变物体表面高度，引发点云高度值的整体变化和局部突变，影响地形建模、建筑物轮廓提取等应用的精度。

针对传统点云数据处理，常通过高斯滤波、中值滤波等经典方法实现高效降噪，保障后续点云建模与目标检测的精度[5~7]。但在雨雪、雾凇等复杂气象场景中，激光雷达采集的点云数据会引入特殊类型噪声，传统滤波方法因未适配此类噪声的物理生成机制与空间分布特性，难以达到理想处理效果。从噪声特性来看，雪粒噪声的空间密度呈现显著的距离相关性，其密度与激光雷达的探测距离成反比，随探测距离增大，雪粒散射信号的能量衰减加剧，噪声点密度呈梯度降低，需要采用特殊滤波方法进行处理。典型点云去噪方法有：

a. 固定半径离群点去除（Radius Outlier Removal Filter，ROR）基于局部空间密度的点云滤波[8]，为每个点设置固定搜索半径，并统计邻域内点的数量。当邻域点数低于预设阈值时，将该点判定为离群点并予以剔除。该方法计算复杂度较低、实现简单，但车载激光雷达点云密度随测距距离增加而逐渐降低，因降雪噪声具有同样明显的距离依赖特性，固定搜索半径难以适应不同距离区域的点云分布。同时，在远距离区域，真实环境点可能因邻域点数不足而被误判为离群点；在近距离区域，固定半径无法有效区分雪噪声与目标点，导致滤波精度下降，故难以满足极寒降雪环境下高精度点云预处理的需求。

b. 统计离群点去除（Statistical Outlier Removal，SOR）通过k近邻（k-Nearest Neighbors，KNN）计算点云平均距离[9]，假设该距离分布近似服从高斯分布，根据全局平均距离和标准差构建距离判别阈值，将超过阈值的点视为离群点并剔除。该方法能够抑制随机分布的离散噪声，在轻度降雪环境下具有一定适用性。但极寒强降雪时，点云空洞导致阈值偏差，噪声去除率下降，无法区分高度畸变点与目标边缘，且模型鲁棒性不足。

c. 基于深度学习的点云去噪网络，结合残差、多尺度融合实现端到端降噪[10]。在中等降雪场景下，具有较高的去噪精度和目标保留能力。然而，该方法对训练数据的分布具有较强依赖性，在极寒强降雪等复杂环境中，雪粒密度、反射特性及点云分布发生明显变化[11]，模型容易出现泛化性能下降的问题。同时，深度学习方法需要高性能计算平台支持，模型训练和部署成本较高，难以满足车载SLAM系统对实时性和轻量化部署的要求。此外，该方法依赖学习的特征表示，未针对激光雷达点云密度随距离变化的特点设计距离自适应滤波策略，因此，在远距离区域的去噪任务中仍存在一定局限性[12]。

本文使用专为自动驾驶在恶劣天气条件设计的CADC数据集。该数据集覆盖城区道路、乡村路网及高速公路等多种典型应用场景，提供高质量的环境感知、

目标检测、跟踪、SLAM及路径规划数据[13]。CADC数据集配备完整的多传感器套件，包括1个LiDAR、8个摄像头和后处理GPS/IMU。数据集中自动驾驶车辆“Autonomoose”在降雪环境下采集的激光雷达点云如图1所示，大量雪粒子随机分布于点云空间，形成离散且密度不均的噪声点，与真实环境目标点云发生混叠，导致场景边缘结构模糊，有效特征点提取困难，为后续开展点云降噪预处理试验提供数据依据。

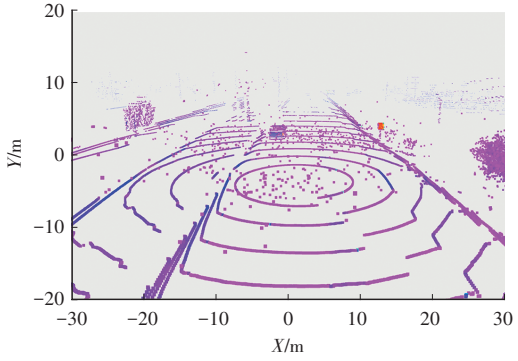


图1　车辆周围降雪点云

3　LIO-SAM框架

LIO-SAM是一种基于激光雷达和惯性测量单元的紧耦合同步定位与建图框架[14]，通过融合多传感器数据实现高精度定位和环境建图[15]，其原理如图2所示。

3.1　点云预处理

在点云预处理流程中，首先，通过设定最小、最大距离阈值，对点云数据进行基于范围的距离滤波，筛除超出阈值范围的近距冗余点与远距噪声点。随后，采用k近邻滤波算法，对初步筛选后的点云逐点搜索其k个空间邻近点，计算各邻近点的空间坐标均值并替代原始点，有效抑制离群点和噪声干扰。

接着，采用体素网格滤波对点云数据执行降采样处理，由于激光雷达单帧数据由一个完整扫描周期内采集的全部点云数据构成，该帧数据仅对应单一时间戳。这种畸变会使数据的几何形状发生变化，从而对建图精度和定位准确性产生负面影响。

为此，LIO-SAM利用当前激光帧起止时刻间的IMU数据，计算旋转增量，并结合IMU里程计数据（由IMU预积分提供）计算平移增量。计算激光帧内各采样时刻相对于帧起始时刻的位姿增量，再基于该增量通过坐标变换算法，将当前采样时刻的激光点云数据统一映射至帧起始时刻的激光雷达坐标系下，即通过位姿变换将所有点云数据映射到起始时刻的坐标系中，得到$\boldsymbol{P}_{\text{start}}$：

$$\boldsymbol{P}_{\text{start}} = \boldsymbol{T}_{\text{start_current}} \cdot \boldsymbol{P}_{\text{current}} \tag{1}$$

式中：$\boldsymbol{T}_{\text{start_current}}$为从当前时刻到起始时刻的位姿变换矩阵，$\boldsymbol{P}_{\text{current}}$为当前时刻的点云数据。

3.2　点云特征提取

LIO-SAM从原始点云中提取边缘点和平面点，进行点云匹配和地图构建[16]。在处理过程中，三维点被投影至二维图像，形成RangeMat，各元素存储对应点到激光雷达原点的距离。在点云预处理阶段，将RangeMat展开为一维向量，利用相邻点间的距离关系计算各点的曲率c，以表征点云局部几何特性。随后，根据曲率大小对点进行排序和筛选，曲率较大的点作为边缘特征点，曲率较小的点作为平面特征点。

$$c = \frac{1}{|S| \cdot \| r_i \|} \left\| \sum_{j \in S, j \neq i} (r_j - r_i) \right\| \tag{2}$$

式中：$|S|$为i点附近的邻域点集合，r_i为点i相对于坐标原点的位置，r_j为集合i点附近的第j个邻域激光点相对于坐标原点的位置。

为了令特征点分布更加均匀，LIO-SAM算法将三维激光雷达点云投影至二维距离图像，为避免特征点集中分布于局部区域，将该二维距离图像沿水平方向均匀

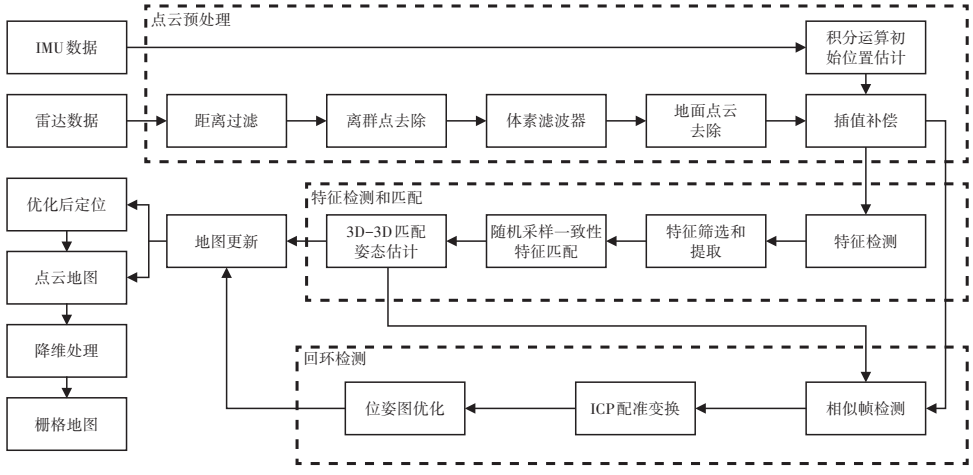


图2　基于紧耦合的雷达惯导定位建图算法原理

划分为6个子区域，分别在各区域内提取边缘特征点和平面特征点。采用随机采样一致算法对特征点匹配结果进行模型参数估计与误匹配剔除，从而实现SLAM任务的地图构建。

3.3 回环检测与扫描匹配

回环检测设计的目的是赋予机器人识别曾到达某场景，使得地图轨迹闭环以消除累积误差的能力。通过识别、匹配当前帧点云与历史地图的点云数据回环检测，有效抑制累积误差，从而降低定位误差与地图构建误差[17]。

LIO-SAM在完成特征提取后，得到当前帧中的边缘特征点和平面特征点，利用IMU预积分提供的估计位姿，将这些特征点从雷达坐标系转换到世界坐标系，转换方式见式(3)。随后在构建的局部地图中，使用最近邻搜索查找对应的地图特征点。

$$\begin{cases} \boldsymbol{x}_{k+1,i}^{\mathrm{W}} = \boldsymbol{R}\cdot\boldsymbol{x}_{k+1,i}^{\mathrm{L}} + \boldsymbol{t} \\ \boldsymbol{t} = (t_x,t_y,t_z)^{\mathrm{T}} \\ \boldsymbol{T}_{K+1}^{\mathrm{W}} = (t_x,t_y,t_z,r_x,r_y,r_z)^{\mathrm{T}} \end{cases} \tag{3}$$

式中：$\boldsymbol{x}_{k+1,i}^{\mathrm{L}}$、$\boldsymbol{x}_{k+1,i}^{\mathrm{W}}$分别为雷达坐标系和世界坐标系下当前帧第$i$个特征点的位置，$\boldsymbol{T}_{K+1}^{\mathrm{W}}$为当前帧雷达位姿(包含平移和欧拉角表示的旋转)，$\boldsymbol{R}$为欧拉角按照$z$、$y$、$x$顺序构建的旋转矩阵，$r_x$、$r_y$、$r_z$分别为绕$x$、$y$、$z$轴方向的旋转角，$\boldsymbol{t}$为当前帧雷达坐标系原点在世界坐标系中的平移向量。

4 DROR滤波器设计

对于典型点云去噪，常用滤波器包括：

a. 体素网格滤波器。将三维空间划分为若干固定尺寸的体素单元，每个体素单元存储落入该空间区域内的所有点。在滤波过程中，计算各体素内所有点坐标的平均值，生成一个新的代表点，从而实现点云降采样，同时保持点云整体空间结构。

b. 统计离群点移除(Statistical Outlier Removal，SOR)滤波器。通过遍历点云中各点，计算该点与其n个最近邻点间的平均距离，根据平均距离分布的均值d_{mean}和标准差σ设置阈值，剔除超过阈值范围的噪声点。

$$d_{\mathrm{mean}} = \frac{d_1 + d_2 + d_3 + \cdots + d_n}{n} \tag{4}$$

$$\sigma^2 = \frac{1}{n}\sum_{i=1}^{n}(d_i - d_{\mathrm{mean}})^2 \tag{5}$$

式中：d_n为点云中各点与其最近邻点的距离，σ^2为距离的方差。

c. 半径离群点移除(Radius Outlier Removal Filter，ROR)滤波器。与SOR滤波器相同，采用k-d树(k-dimensional tree)数据结构进行点云空间索引构建，从而实现高效的邻域搜索。该滤波器通过预设搜索半径r与最小邻域点数阈值k_{min}定义离群点判定规则：对输入点云中的每个目标点p_i，在k-d树索引支持下统计其搜索半径范围内的邻域点数量N_i，若$N_i < k_{\mathrm{min}}$，则判定p_i为噪声点或离群点，并执行滤除操作，最终输出去噪后的点云数据。

体素网格滤波器、SOR滤波器和ROR滤波器的可视化点云结果如图3所示。3种滤波器中，体素网格滤波器的除雪效果最差。这是由于在下采样过程中，点云的雪点相距太远，无法合并到同一体素中。与体素网格滤波器相比，SOR滤波器的效果有所提升。点云中部分明显的雪点均被移除，但仍存在点群。虽然增加过滤量能够减少残留雪簇的数量，但同时会去除重要的环境特征。

ROR滤波器的除雪效果最好，但以较小的搜索半径运行滤波器时，会去除过多重要的环境特征(见图3c)。ROR会去除所有距离传感器超过一定距离的点，而该距离依赖于滤波器的搜索半径和激光雷达的水平角分辨率。

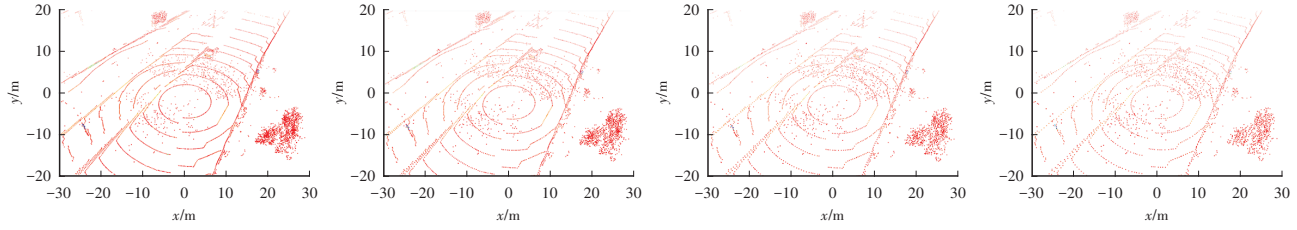
鉴于ROR滤波器对所有点采用固定搜索半径，未能考虑远距离物体的密度变化，为此，本文设计动态半径异常点去除滤波器，根据点p与传感器的距离，动态调整其搜索半径S_p，确保半径足以捕获结构清晰物体上的邻近点。

对于原始点云中的点p，计算该点与传感器的距离：

$$r_p = \sqrt{x_p^2 + y_p^2} \tag{6}$$

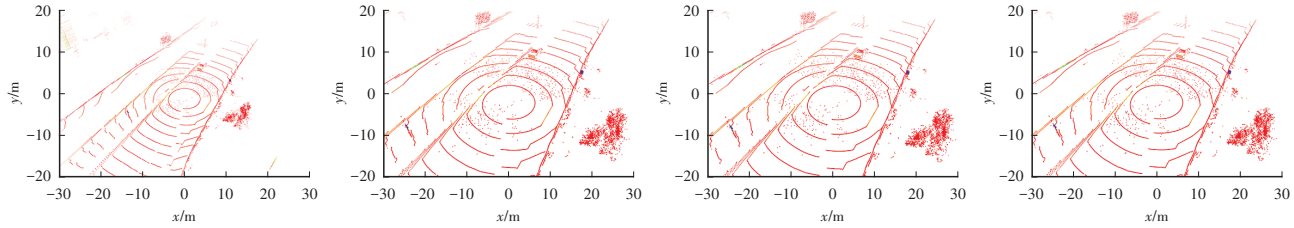
式中：(x_p,y_p)为p在激光雷达坐标系的坐标。

若$r_p < S_{\mathrm{min}}$，其中，S_{min}为最小搜索半径，则将S_{min}设

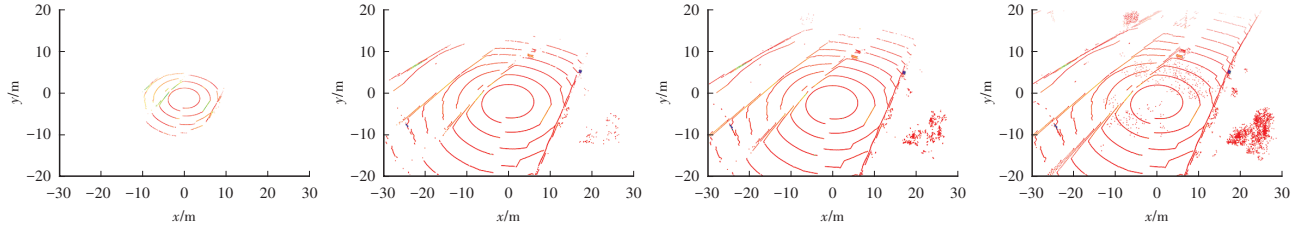


体素尺寸0.2 m　体素尺寸0.3 m　体素尺寸0.4 m　体素尺寸0.5 m

(a)体素网格滤波器



(b)统计离群滤波器



(c)半径滤波器

图3　不同滤波器可视化点云结果

为S_p，避免对靠近车辆的点使用过小的搜索半径；反之，按式(7)计算搜索半径。

$$S_p = \beta \times (r_p \times \alpha),\quad \beta > 1 \tag{7}$$

式中：α为激光雷达的水平角分辨率，β为乘数因子。

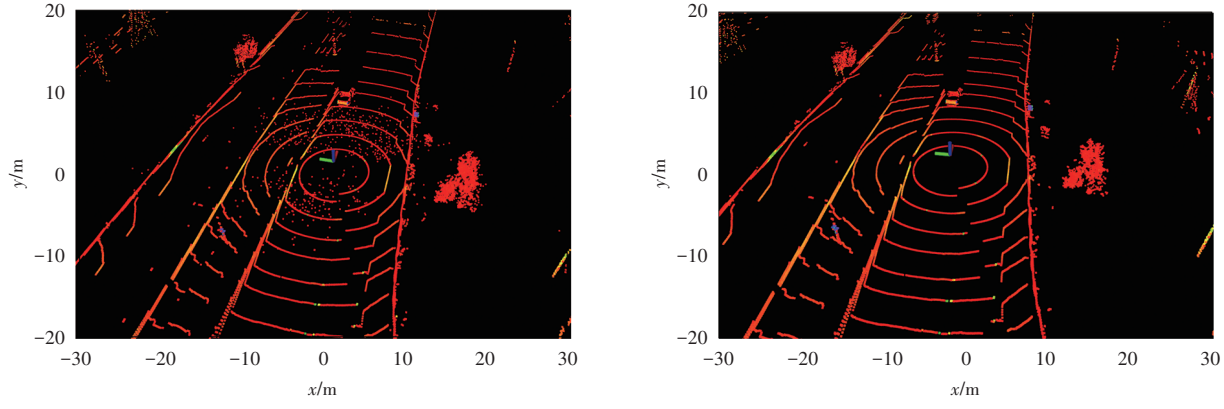
确定S_p后，基于邻域计数的异常值剔除，执行最近邻搜索，找出点p在S_p内邻近点的数量k。若$k < k_{\min}$，其中，$k_{\min}$为所需最小相邻点数量，将点p判定为异常点；反之，将其保留为有效点。

5　试验结果与分析

为验证DROR滤波器的噪声抑制与远距离特征保留性能，选取CADC数据集的真实道路积雪场景开展滤波效果验证，道路场景激光点云对比结果如图4所示，原始点云数据包括建筑物(右侧)、地面点(圆形)、路边点以及积雪点(随机分布于中心区域)，存在大量零散的“鬼点”(雪花噪声与异常值)，这些伪像干扰了场景的真实表征，如道路周边和远处区域分布着无意义的离散点。DROR有效去除雪花噪声和异常值，同时保留了距激光雷达较远的大部分环境特征。

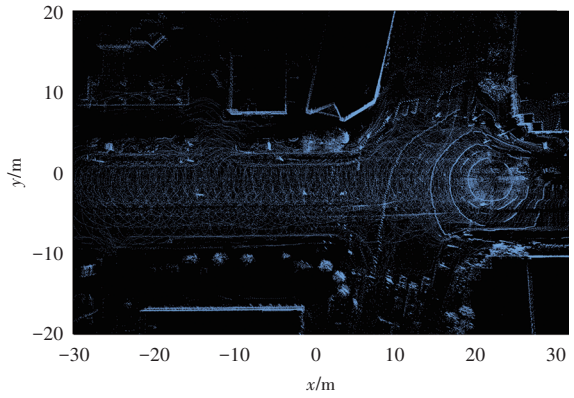
基于CADC数据集重建地图，由于LIO-SAM建图中存在大量由雪花噪声、异常值形成的“冗余点”，场景细节(如道路边缘、建筑轮廓)被干扰，整体点云分布较乱，如图5所示。经DROR滤波处理后，噪声点被有效滤除，地图更洁净，道路结构、周边障碍物的关键轮廓清晰连贯，准确反映了场景的真实空间占用情况。

为量化DROR滤波器在积雪车载点云场景的去噪综合性能，使用CADC数据集，针对CADC雪景场景的DROR参数定义如下：缩放因子$\beta \in (1.7,1.9)$(适用于表面倾角≤15°)，最小搜索半径$S_{\min} \in (0.22\ \text{m},0.25\ \text{m})$，可覆盖近距离雪花噪声，最小邻域阈值$k_{\min} \in (5,6)$。选用精度、召回率、单帧点云处理耗时作为评价指标，基于CADC积雪数据集开展多滤波器对比试验，结果如表1所示。

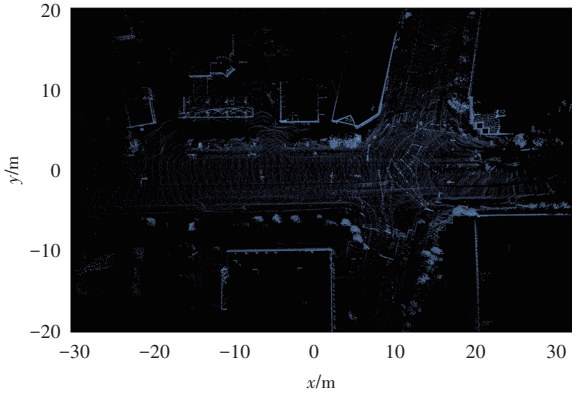


(a)原始点云　　(b)处理后点云

图4　道路场景激光点云对比



(a)原始点云



(b)处理后点云

图5　DROR滤波后建图效果对比

表1　去噪结果

滤波器	平均执行时间/ms	精度/%	召回率/%
DROR	781.63	74.63	91.06
ROR	97.05	58.94	92.65
SOR	130.84	75.04	75.63
VOXEL	120.11	60.78	69.25

由表1可知，VOXEL的精度与召回率均处于较低水平，对雪地噪声的针对性不足；SOR召回率较低，会丢失大量有效环境特征，不利于LIO-SAM建图；ROR执行效率最高，但精度显著低于DROR，易因噪声残留导致LIO-SAM特征误匹配；DROR在精度、召回率方面综合权衡性能最优，较高的召回率能够完整保留场景有效几何特征，较高的去噪精度可高效滤除雪花异常点，为后续LIO-SAM在定位和建图环节的性能提升提供保障。虽然DROR运算耗时较长，但结合建图多为离线预处理的工程场景，其时间代价具有工程合理性。

从扫描匹配精度、轨迹估计精度、地图几何一致性3个维度构建量化评价体系。在扫描匹配方面，采用笛卡尔坐标系三轴欧氏距离计算平移配准误差，基于横滚、俯仰、偏航欧拉角计算旋转配准误差，最终误差为所有帧数据中指标的均方根误差。

在姿态估计方面，绝对轨迹误差(Absolute Trajectory Error，ATE)反映全局姿态精度，相对轨迹误差(Relative Trajectory Error，RTE)则捕捉局部姿态漂移。其中，ATE利用迭代最近点配准(Iterative Closest Point，ICP)算法，将LIO-SAM输出轨迹与CADC基准轨迹对齐，计算每帧姿态与基线的欧几里得距离，并取其均方根误差；RTE为LIO-SAM轨迹与真实轨迹在连续100帧间的相对姿态偏差的均方根误差。

在地图一致性方面，采用ICP配准误差与边缘法向量一致性2项指标进行评估，量化LIO-SAM生成的地图与CADC真实场景间的契合程度。其中，ICP配准误差通过将生成的点云地图与CADC数据集中的对应真实场景进行ICP算法对齐，再计算配准结果的均方根误差。边界法向量一致性定义为：在100条选定的代表性边界(如路缘石、建筑转角)中，边界点法向量与真实法向量偏差≤5°的点所占比例。

根据上述评价指标，分别基于原始点云、DROR滤波处理后的点云开展LIO-SAM建图测试，结果如表2所示。

表2　原始点云与DROR滤波点云的建图精度对比

指标		原始点云	去噪后点云
平移误差均方根误差/m	x轴	0.22	0.11
	y轴	0.19	0.10
	z轴	0.15	0.08
旋转误差均方根误差/(°)	滚转	1.4	0.6
	俯仰	1.1	0.5
	偏航	1.6	0.7
绝对轨迹误差/m		1.68	0.92
相对轨迹误差/m		0.72	0.35
ICP配准误差/m		0.52	0.25
边缘法线一致性/%		60	86

由表2可知，在CADC雪景场景中，DROR滤波有效消除雪花噪声与异常值，显著提升LIO-SAM性能：扫描匹配误差降低45%~56%，ATE减少45.2%，地图ICP配准误差缩减48.6%~51.9%。这些降幅大幅增强了系统在雪地环境中的定位与建图精度。此外，边缘法向量一致性提升32.4%至43.3%，证实针对CADC数据集优化的DROR参数能防止点云特征丢失并保持地图细节完整性。

因此，DROR能够显著优化扫描匹配精度与轨迹求解精度，2组点云数据源输入LIO-SAM，生成运行轨迹整体趋于一致，表明2种输入条件下位姿求解的宏观路

径未发生明显偏移。但基于原始含噪点云构建的场景地图混杂了大量由雪花噪声形成的伪点结构，真实空间结构被干扰遮挡，DROR去噪点云重建的地图，整体空域结构整洁度大幅提升，有效滤除非目标噪声，道路走向、周边障碍物轮廓具备良好的连续性与完备性，能够高精度复现实景的空间占用分布特征。

6 结束语

本文针对极寒降雪环境下LIO-SAM点云预处理过程中雪花噪声干扰严重的问题，提出基于DROR滤波算法的点云预处理方法，并将其集成至LIO-SAM系统。基于CADC数据集开展试验，本文方法能够有效去除雪花噪声的同时，保留更多环境特征，提高点云质量，并进一步改善扫描匹配精度、轨迹估计精度及地图一致性。未来，将进一步结合语义信息和深度学习方法，提升复杂天气条件下SLAM系统的环境适应能力和实时性能。

参 考 文 献

[1] ZHANG J, SINGH S. LOAM: LiDAR Odometry and Mapping in Real-Time[C]// Robotics: Science and Systems Conference. Rome, Italy: RSS, 2014.

[2] SHAN T X, ENGLOT B. LeGO-LOAM: Lightweight and Ground-Optimized LiDAR Odometry and Mapping on Variable Terrain[C]// 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, Spain: IEEE, 2018: 4758-4765.

[3] SHAN T X, ENGLOT B, MEYERS D, et al. LIO-SAM: Tightly-Coupled LiDAR Inertial Odometry via Smoothing and Mapping[C]// 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA: IEEE, 2020: 5135-5142.

[4] PITROPOV M, GARCIA D E, REBELLO J, et al. Canadian Adverse Driving Conditions Dataset[J]. The International Journal of Robotics Research, 2021, 40(4/5): 681-690.

[5] BELYAEV A, SCHALL O, SEIDEL H. Adaptive Feature-Preserving Non-Local Denoising of Static and Time-Varying Range Data[J]. Computer-Aided Design, 2008, 40(6): 701-707.

[6] HU W, LI X, CHEUNG G, et al. Depth Map Denoising Using Graph-Based Transform and Group Sparsity[C]// 2013 IEEE 15th International Workshop on Multimedia Signal Processing (MMSP). Pula, Italy: IEEE, 2013.

[7] WEYRICH T, PAULY M, KEISER R, et al. Post-Processing of Scanned 3D Surface Data[C]// Proceedings of the First Eurographics Conference on Point-Based Graphics. Goslar Germany: SPBG, 2004: 85-94.

[8] CHARRON N, PHILLIPS S, WASLANDER S L. De-Noising of LiDAR Point Clouds Corrupted by Snowfall[C]// 2018 15th Conference on Computer and Robot Vision (CRV). Toronto, Canada: IEEE, 2018: 254-261.

[9] CAO Y M, HUANG H, YU D L. Filter Methods for Removing Falling Snow from Light Detection and Ranging Point Clouds in Snowy Weather[J]. Sensors and Materials, 2022, 34.

[10] YU M Y, VASUDEVAN R, JOHNSON-ROBERSON M. LiSnowNet: Real-time Snow Removal for LiDAR Point Clouds[C]// IEEE/RSJ International Conference on Intelligent Robots and Systems. Kyoto, Japan: IEEE, 2022: 6820-6826.

[11] ZHANG Y X, DING M, YANG H T, et al. L-DIG: A GAN-Based Method for LiDAR Point Cloud Processing under Snow Driving Conditions[J]. Sensors, 2023, 23(21).

[12] BOS J P, CHOPP D, KURUP A, et al. Autonomy at the end of the Earth: An Inclement Weather Autonomous Driving Data Set[C]// Autonomous Systems: Sensors, Processing, and Security for Vehicles and Infrastructure 2020. California, United States: SPIE, 2020: 36-48.

[13] ALFEQY L, ABDELMUNIM H, MAGED S A, et al. Kalman Filter-Based Fusion of LiDAR and Camera Data in Bird's Eye View for Multi-Object Tracking in Autonomous Vehicles[J]. Sensors, 2024, 24(23): 7718.

[14] SHAN T X, ENGLOT B, RATTI C, et al. LVI-SAM: Tightly-Coupled LiDAR-Visual-Inertial Odometry via Smoothing and Mapping[C]// 2021 IEEE International Conference on Robotics and Automation (ICRA). Xi'an, China: IEEE, 2021: 5692-5698.

[15] 孙国祥, 黄银锋, 汪小昱, 等. 基于LIO-SAM建图和激光视觉融合定位的温室自主行走系统[J]. 农业工程学报, 2024, 40(3): 227-239.
SUN G X, HUANG Y F, WANG X C, et al. Autonomous Navigation System in a Greenhouse Using LIO-SAM Mapping and Laser Vision Fusion Localization[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(3): 227-239.

[16] SHEN B K, XIE W M, PENG X D, et al. LIO-SAM++: A LiDAR-Inertial Semantic SLAM with Association Optimization and Keyframe Selection[J]. Sensors, 2024, 24(23).

[17] 李荣华, 祁宇峰, 谢辉, 等. 面向未知环境的紧耦合激光SLAM方法[J]. 红外与激光工程, 2023, 52(9): 135-144.
LI R H, QI Y F, XIE H, et al. Tightly Coupled LiDAR SLAM Method for Unknown Environment[J]. Infrared and Laser Engineering, 2023, 52(9): 135-144.

（责任编辑 瑞 秋）

修改稿收到日期为2025年11月24日。