

恶劣天气下基于退化特征一致性学习的点云语义分割方法

安怡¹, 刘书信², 贺丽君¹, 李凡¹

(1. 西安交通大学电子与信息学部, 710049, 西安; 2. 西南技术物理研究所, 610041, 成都)

摘要: 针对雨、雪、雾等恶劣天气造成激光雷达点云点丢失、遮挡和几何扰动, 导致三维语义分割性能下降, 尤其影响行人、自行车等小目标分割精度的问题, 提出一种基于退化特征一致性学习的点云语义分割方法。首先, 构建由细粒度语义实例增强和空间分区距离感知扰动组成的数据增强模块, 通过几何扰动模拟和小目标实例扩充, 增强模型对结构变化及小目标特征的学习能力; 其次, 利用点云体素特征提取网络对点云进行编码, 获得体素特征表示; 最后, 对体素特征施加随机退化, 构建“良好—退化双分支”, 并通过一致性约束提升网络在特征受损条件下的稳健表征能力。使用公开 SemanticSTF 数据集对所提方法进行实验验证, 结果表明: 该方法能够有效改善恶劣天气下的点云语义分割性能; 在性能指标方面, 平均交并比较基准模型提高 10.7%, 并在行人、自行车等小目标类别上取得更优的分割结果。研究结果可为复杂天气环境下三维感知系统的安全可靠应用提供参考。

关键词: 语义分割; 恶劣天气; 泛化性

中图分类号: TP391 **文献标志码:** A

DOI: 10.7652/xjtubXXXXXX001 **文章编号:** 0253-987X(XXXX)XX-0001-11

Point Cloud Semantic Segmentation Based on Degraded Feature Consistency Learning under Adverse Weather Conditions

AN Yi¹, LIU Shuxin², HE Lijun¹, LI Fan¹

(1. Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. The Southwestern Technical Institute of Physics, Chendu 610041, China)

Abstract: To address the issues of point loss, occlusion, and geometric distortion in LiDAR point clouds caused by adverse weather conditions such as rain, snow, and fog, which lead to degraded performance in 3D semantic segmentation and particularly affect the segmentation accuracy of small objects like pedestrians and bicycles, a point cloud semantic segmentation method is proposed based on degraded feature consistency learning. First, a data augmentation module consisting of fine-grained semantic instance enhancement and spatially partitioned distance-aware perturbation is constructed. Through geometric perturbation simulation and small object instance expansion, the model's learning capability for structural variations and small object features is enhanced. Second, a point cloud voxel feature extraction network is used to encode point clouds to obtain voxel feature representations. Finally, random degradation is applied to voxel features to construct a "clean-

degraded dual-branch" structure, and the robust representation capability of the network under feature corruption conditions is improved through consistency constraints. The proposed method is experimentally validated on the public SemanticSTF dataset. The results show that this method can effectively improve the performance of point cloud semantic segmentation under adverse weather conditions. In terms of performance metrics, the mean Intersection over Union (mIoU) is 10.7% higher than that of the baseline model, and better segmentation results are achieved for small object categories such as pedestrians and bicycles. The research results can provide a reference for the safe and reliable application of 3D perception systems in complex weather environments.

Keywords: semantic segmentation; adverse weather; generalization

点云语义分割是自动驾驶环境感知中的核心任务,旨在实现逐点语义信息的高精度识别,为环境建模、路径规划与决策控制提供可靠依据^[1-3]。作为当前自动驾驶系统的主流感知传感器,激光雷达凭借其高精度的空间测量能力与良好的环境适应性,能够稳定获取三维场景的结构信息^[4-5]。然而在真实道路环境中,雨、雪、雾等恶劣天气条件会显著干扰激光雷达的探测性能,导致回波信号衰减、噪声增加等问题^[6],使点云数据出现失真(如点丢失、遮挡及几何扰动)现象,从而导致现有点云语义分割模型在恶劣天气场景中出现显著的性能下降,影响全天候自动驾驶系统的稳定性与安全性^[7-8]。

为应对上述问题,现有研究主要围绕域适应^[9]与域泛化^[10]两条技术路径展开。域自适应学习旨在不同域间特征分布存在差异的情况下,提高模型对目标域的适应能力^[11-14]。Jiang等人^[12]提出边界感知点云域自适应网络,通过域共享与域私有双分支分别提取跨域通用特征和域特有特征,并利用边界信息优化分割结果。Yuan等人^[13]提出类级对抗网络,通过多尺度域条件模块提取域相关特征,并结合点视角与体素视角的预测一致性,提高模型在目标域的分割性能。然而,此类方法对目标域数据依赖较强,难以覆盖复杂多变的天气模式,因而在未知天气条件下的泛化能力受限。

相比之下,域泛化方法^[14]旨在从单个或多个相关但不同的源域中学习可泛化模型,且训练过程中不使用目标域数据,目前已在计算机视觉任务中得到广泛研究^[15-17]。然而,点云具有不同于图像的数据结构与空间特性,其域泛化问题需要进行针对性建模^[18-19]。例如,Park等人^[20]通过设计可学习的点云丢失模式和几何扰动模式,模拟雨雪条件下的点缺失与几何扰动等典型退化过程,提升模型在恶劣环境下的分割性能;随后,Park等人^[21]进一步提出特征绑定与激光束特征蒸馏策略,增强激光束级几

何一致性,提升小目标类别的分割性能;Xiao等人^[22]则利用跨样本原型表征捕捉更具迁移性的语义结构,提高模型在不同天气条件下的稳健性。此类方法无需目标域数据,能够有效提升模型在恶劣天气下的泛化能力,已成为解决恶劣天气下点云语义分割性能退化问题的重要研究方向。

然而,现有域泛化方法仍面临两大核心挑战:第一,恶劣天气导致点云失真(点丢失、遮挡及几何扰动等),使得模型性能显著低于晴朗天气场景,尤其是在行人、自行车等小目标类别上分割精度急剧下降;第二,现有方法在提升恶劣天气场景泛化性的过程中,难以同时兼顾模型在晴朗天气场景下的分割稳定性,从而限制了其实际应用价值。

针对上述挑战,本文受已有一致性学习方法^[23-26]的启发,将一致性学习引入恶劣天气点云退化建模中。已有研究表明,通过约束不同扰动状态下的预测一致性,能够提升模型在扰动条件下的预测稳定性。基于此,本文提出一种恶劣天气下基于退化特征一致性学习的点云语义分割方法。具体而言,在特征层面,通过对体素特征施加随机退化约束,构建“良好—退化”双分支一致性学习方法,增强网络在特征受损条件下对空间结构和语义信息的稳健表征能力;在数据层面,设计细粒度语义实例增强与空间分区距离感知扰动相结合的数据增强策略,通过模拟恶劣天气下的点云几何扰动并扩充小目标实例,提升模型对点云结构变化和小目标特征的学习能力。实验结果表明,本文方法在多种恶劣天气条件下实现了稳定且显著的性能提升,优于现有方法。

1 基于退化特征一致性学习的点云语义分割方法总体框架

如图1所示,本文提出了一种恶劣天气下基于退化特征一致性学习的点云语义分割方法。首先,

输入点云通过数据增强模块构造退化样本并提升样本多样性;然后,利用点云体素特征提取网络提取体素特征;最后,通过基于退化特征的一致性学习模块,在特征退化条件下学习稳定的语义表示,并生成准确的语义预测结果。

在数据增强阶段,该模块通过基于细粒度语义的实例增强与空间分区的距离感知扰动协同实现,从微观实例和宏观空间分布两个层面出发。通过空间离散化分区、局部几何变换和目标实例融合,有效缓解了稀有类别样本匮乏和几何结构扰动的问题。

在点云体素特征提取阶段,采用稀疏三维 U-Net^[27] 结构以适配点云的稀疏性与非均匀分布特

征。稀疏卷积在保持空间连续性的同时显著降低了计算复杂度,结合跳跃连接的多层次编解码结构能够有效捕获多尺度空间信息并保留局部细节,从而形成具有丰富空间语义的体素特征表示。

在特征建模阶段,提出基于退化特征的一致性学习模块,以增强模型对恶劣天气引起的信息缺失和特征削弱的适应能力。该模块作用于体素特征,通过随机特征丢弃显式构造特征退化过程,模拟雨、雾、雪等条件下由遮挡和散射引起的点丢失与局部结构缺失。构建“良好—退化”双分支一致性学习框架,增强网络在特征受损条件下对空间结构和语义信息的稳健表征能力。提升模型在恶劣天气条件下的分割性能。

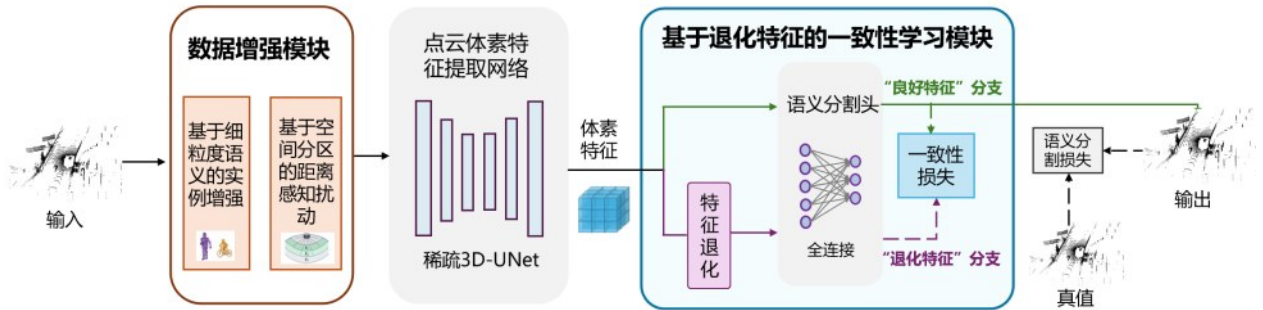


图1 恶劣天气下基于退化特征一致性学习的点云语义分割方法总览

Fig. 1 Overview of the point cloud semantic segmentation based on degraded feature consistency learning under adverse weather conditions

2 数据增强与良好—退化双分支一致性学习方法

2.1 数据增强模块

如图2所示,该模块由基于细粒度语义的实例增强和基于空间分区的距离感知扰动两部分组成。基于细粒度语义的实例增强以实例点云为处理对象,通过几何变换与实例级融合扩充小目标实例。基于空间分区的距离感知扰动则从整体空间结构出发,通过对点云空间的离散化分区施加分层空间变换,以模拟环境噪声引起的非均匀几何偏移。

2.1.1 基于细粒度语义的实例增强

该方法通过空间划分、局部几何扰动和实例融合,增加小目标实例的有效样本,从而提升模型在恶劣天气下对目标物体的分割能力。设原始点云为 $P = \{(x_i, y_i, z_i)\}_{i=1}^N$, 首先,将点云数据按其空间位置划分为多个区域。划分的方式可以基于方位角或俯仰角。方位角计算公式为:




图2 数据增强模块

Fig. 2 Data Augmentation Module

$$\theta = \arctan\left(\frac{y}{x}\right) \quad (1)$$

俯仰角计算如下为:

$$\phi = \arctan\left(\frac{z}{\sqrt{x^2 + y^2}}\right) \quad (2)$$

在每个区域内,根据预先定义的目标类别集合 C (主要包含稀有类别及小目标) 筛选待增强的点云

实例 P_s 。类别筛选规则为:

$$P_s = \{P_i | L_i \in C\} \quad (3)$$

式中: P_i 为原始点云中的第 i 个点。 L_i 为点 P_i 的类别标签。

随后对筛选出的实例点集施加高斯扰动,模拟恶劣天气中出现的噪声点,扰动公式为:

$$P_g = P_i + \epsilon, \epsilon \in N(0, \sigma^2) \quad (4)$$

式中: $N(0, \sigma^2)$ 为均值为 0, 方差为 σ^2 的高斯噪声。

在完成局部几何扰动后,进一步施加包含刚性变换和非刚性变换的几何变换。刚性变化在保持目标形状与结构不变的基础上调整空间位置和姿态。

设定变换后的点云 P' , 刚性变换公式为:

$$P' = R \cdot P + T \quad (5)$$

式中: R 为旋转矩阵, T 为平移向量。

非刚性变换通过尺度缩放改变目标形态,以增强模型对位置、姿态和形态变化的适应能力。其形式定义为:

$$P' = s \cdot P \quad (6)$$

式中: s 为随机选择的缩放因子。

最后需要将变化后的点云区域与原始点云进行组合,生成新的点云数据 $P_{\text{aug},1} = P \cup P'$ 。

2.1.2 基于空间分区的距离感知扰动

基于空间分区的距离感知扰动主要包含距离感知扰动和空间分区重组两个部分。距离感知扰动通过使噪声强度随点到传感器距离动态变化;空间分区重组则通过俯仰角划分局部空间区域,并在不同区域之间引入退化差异。对于点云中的点,首先通过其空间坐标映射得到对应的俯仰角。并依据视角范围,将原始点云划分为 K 个区域集合 $\{R_1, R_2, R_3, \dots, R_K\}$ 。

为模拟实际感知环境中干扰分布的非均匀性,该模块采用基于分区索引奇偶性的交替采样策略,对不同扰动量级的场景进行空间重组。设当前场景点云为 P_A, P_B 为引入外部噪声特征的候选场景点云。增强后的点云 $P_{\text{aug},2}$ 可表示为:

$$P_{\text{aug},2} = \bigcup_{k=1}^K P'_k \quad (7)$$

式中: P'_k 为第 k 个分区对应的点集合,可表示为:

$$P'_k = \begin{cases} P_{\{A,k\}}, & k \equiv 0 \pmod{2} \\ \{p + \epsilon | p \in P_{\{B,k\}}\}, & k \equiv 1 \pmod{2} \end{cases} \quad (8)$$

式中: $P_{\{A,k\}}$ 和 $P_{\{B,k\}}$ 分别为当前场景和候选场景在分区 R_k 内的点集, ϵ 为施加在点坐标上的高斯噪声,其中扰动强度由距离动态决定,定义如下:

$$\sigma = \sigma_0 \cdot (1 + \gamma \cdot \frac{r}{r_{\max}}) \quad (9)$$

式中: r 为点到传感器的距离, $r_{\max}$ 为预设的最大距离, σ_0 与 γ 分别代表基础的噪声强度与距离调节因子。

此外,该模块采用概率触发的预处理机制,在丰富输入分布的同时,避免过度增强造成的点云结构退化。

2.2 点云体素特征提取网络

本文以 Minkunet^[27] 作为点云体素特征提取网络,设输入点云为 $P \in \mathbb{R}^{N \times C}$, 其中 N 表示点云的数量, C 为点云的特征维度,包含三维坐标、反射强度等信息。首先,根据预设的体素量化步长 d ,将点云划分为规则的三维空间体素网格。对于每个非空体素,将其内部所有点的初始特征进行平均池化,得到体素级的初始特征表示,记为 $V_m \in \mathbb{R}^{M \times C}$, 其中 M 表示非空体素的数量。随后,该稀疏体素输入到三维 U-Net 中进行特征提取,最终获得体素级的点云特征 $V \in \mathbb{R}^{M \times C'}$, 其中 C' 表示提取后的高维特征通道数。

2.3 基于退化特征的一致性学习模块

在雨、雪、雾等恶劣天气下,点云易出现随机缺失与局部遮挡,破坏局部几何结构并引起特征偏移,使模型在正常条件下学习的“几何—语义”映射稳定性下降,进而导致同一语义类别出现错误分割。为解决这一问题,本文提出一种基于退化特征的一致性学习模块。设点云通过体素化后得到的点云序列为 V , 提取的体素特征 F 表示为:

$$F = f_{\theta}(V) \quad (10)$$

式中: f_{θ} 为点云骨干网络。

在训练阶段,特征 F 被同步送入双分支预测结构进行一致性建模。“良好特征”分支利用原始特征进行语义预测,作为几何信息相对完整条件下的参考基准;“退化特征”分支则在特征层引入随机掩码算子,通过抑制部分体素的特征响应,构造特征信息缺失的退化状态,用于近似描述恶劣天气导致的局部观测缺失在特征空间中的表现,而不是对雨、雾、雪条件下具体遮挡位置的逐点物理仿真,表示如下:

$$\tilde{F} = F \odot m \quad (11)$$

式中: m 为服从参数 $1 - p$ 的伯努利随机掩码向量; p 为特征退化概率, m 中的每个元素以概率 $1 - p$ 取值 1,表示对应体素特征被保留,以概率 p 取值为 0,表

示对应体素特征被抑制,用于构造特征层面的退化状态; $\odot$ 为逐元素乘法。

随后,两分支的特征分别通过参数共享的分割解码头,映射为对应的类别预测分布:

$$Y = h_{\phi}(F), \tilde{Y} = h_{\phi}(\tilde{F}) \quad (12)$$

式中: h_{ϕ} 为分割解码头, Y 与 $\tilde{Y}$ 分别表示完整特征与退化特征条件下的语义预测概率分布。

为约束模型在特征退化条件下保持稳定的语义响应,引入基于Kullback-Leibler^[28](KL)散度的一致性约束,用于对齐“良好特征”与“退化特征”的语义预测,定义为:

$$L_c = KL(Y \parallel \tilde{Y}) \quad (13)$$

该机制通过跨分支语义对齐,使受损特征分支获得与良好特征分支一致的预测结果。不同于输入级增强和输出级约束,该方法直接作用于体素级空间一语义特征,通过显式模拟特征受损过程,引导网络挖掘对退化不敏感的稳健特征表征。

2.4 损失函数

训练阶段联合优化语义分割损失与一致性损失。其中,“良好特征”分支用于学习基础语义判别能力,分割损失采用交叉熵定义为:

$$L_{\text{seg}} = \frac{1}{N} \sum_{i=1}^N \text{CE}(Y_i, y_i) \quad (14)$$

式中: N 为点的数量, $\text{CE}(\cdot)$ 表示交叉熵函数, Y_i 表示“良好特征”分支对第 i 个点的语义预测, y_i 为对应的真实语义标签。

此外,引入“良好特征”分支与“退化特征”分支之间的一致性约束 L_c ,以强化模型对特征退化的泛化性。综合两类损失,整体优化目标可表示为:

$$L = L_{\text{seg}} + \lambda_c L_c \quad (15)$$

式中: λ_c 为一致性损失的权重。

3 实验与讨论

3.1 参数设置

模型输入为单帧点云数据。首先对点云进行体素化处理,体素尺寸为 $0.05 \text{ m} \times 0.05 \text{ m} \times 0.05 \text{ m}$,每帧最多保留80 000个体素。训练阶段采用随机梯度下降(SGD)优化器,初始学习率为0.24,权重衰减为0.0001,训练批次大小为8,训练共进行30轮次。训练过程中,一致性约束权重 λ_c 设置为0.5,特征退化概率设置为0.3。

本文所有实验均在配备NVIDIA GeForce RTX 3090 GPU的服务器上完成,实验环境采用Python 3.8,深度学习框架为PyTorch 1.13.0,

CUDA版本为11.6。为保证实验结果的可复现性,随机种子统一设置为0。

3.2 数据集构建

本研究采用SemanticKITTI数据集^[29]和SemanticSTF数据集^[22]开展实验。SemanticKITTI包含丰富的三维点云及逐点语义标注,覆盖城市道路环境中的多类典型场景,是点云语义分割领域常用的公开数据集。SemanticSTF采集于真实恶劣天气环境,共包含2076帧点云数据,其中雪天694帧、浓雾637帧、薄雾631帧、雨天114帧。该数据集划分为1326帧训练集、250帧验证集和500帧测试集,并采用与SemanticKITTI相近的语义类别体系。图3展示了SemanticSTF数据集中不同恶劣天气条件下点云语义标签的可视化示例。




图3 不同恶劣天气条件下点云语义标签的可视化示例

Fig. 3 Visualization examples of point cloud semantic labels under different adverse weather conditions

3.3 对比算法

本文选取了涵盖基础骨干网络、数据增强方法及域泛化方法等多种对比算法,包括基准模型MinkUNet^[27],点云数据增强方法PolarMix^[30]和LaserMix^[31],面向恶劣天气场景的PointDR^[22]和SJ+LPD^[20],以及域泛化方法DGUIL^[32]。

所有对比方法均基于公开代码,在统一实验设置下使用SemanticKITTI数据集重新训练,在SemanticSTF数据集上测试。对于PointDR方法,同时报告其官方默认训练轮次和统一训练轮次下的结果,以进行更全面的比较。

3.4 评价指标

本文采用平均交并比(mean Intersection over

Union, mIoU)作为主要评价指标。对于每个语义类别,交并比表示预测区域与真实区域交集占二者并集的比例;mIoU为所有参与评测类别交并比的平均值,用于综合衡量模型在各语义类别上的分割性能。

此外,本文还采用精确率、召回率和F1值作为辅助评价指标。精确率衡量模型预测为某一类别的点中实际属于该类别的比例,主要反映预测结果的准确性;召回率衡量真实属于某一类别的点中被模型正确识别出来的比例,主要反映模型对目标类别的覆盖能力;F1值综合考虑精确率和召回率,用于评价模型在预测准确性和目标覆盖能力之间的平衡性能。

3.5 实验结果

3.5.1 对比实验结果

表1给出了不同方法在SemanticSTF验证集上的三维语义分割性能对比结果。基准模型在恶劣天气条件下取得29.8%的mIoU。PolarMix与LaserMix分别取得14.5%和14.9%的mIoU,均低于基准模型,说明场景级拼接和实例级复制难以有效模拟恶劣天气造成的点云退化,未能改善模型的分割性能。PointDR取得23.4%的mIoU,采用默认50轮的训练设置时可达30.9%(PointDR*),表明几何样式随机化与特征嵌入聚合能够在一定程度上缓解天气变化引起的分布偏移。DGUIL取得32.2%的mIoU,表明不确定性建模能够增强模型对天气变化的适应能力。SJ+LPD取得39.4%的mIoU,说明几何扰动建模与点缺失学习有助于提高模型在恶劣天气下的分割性能。本文方法取得最高的40.5% mIoU,较基准模型提升10.7个百分点,并优于其他对比方法。

从类别层面分析,相比SJ+LPD,本文方法在“person”、“bicyclist”和“motorcyclist”类别上的结果分别由45.0%、9.0%、36.1%提升至56.5%、20.2%和50.1%。这些类别对应的目标通常点数较少,在恶劣天气下更易受到点云稀疏、局部缺失和噪声干扰。上述结果表明,本文方法能够有效提升点数较少类别的分割精度,并增强模型对恶劣天气下点云退化的适应能力。

表2展示了不同方法在精确率、召回率及F1值上的实验结果。实验表明,所提出的算法在所有关键评价指标上均表现优异,F1值达到57.3%,相比于基线模型提升了11%;与SJ+LPD算法(F1值为55.7%)相比,性能提升了1.6%,体现了在精确率

表1 SemanticSTF验证集上3D语义分割性能结果对比

Table 1 Comparison of 3D semantic segmentation performance of different methods on the SemanticSTF validation set

方法	mIoU	car	bi.cle	mt.cle	truck	oth.v	Pers.	bi.clst	mt.clst	road	parki.	sidew.	othe.g.	build.	fence	veget.	trunk	Terra.	pole	Traf.
基准模型 ^[27]	29.8	56.9	0.8	0.0	33.4	18.4	30.3	22.8	32.2	39.4	11.1	22.0	3.7	75.3	51.9	49.2	35.6	35.5	26.8	21.3
PolarMix ^[30]	14.5	18.4	1.7	0.0	2.7	2.6	2.2	0.0	0.4	48.8	4.5	16.7	1.7	33.7	36.4	41.0	6.7	36.1	18.3	4.1
LaserMix ^[31]	14.9	21.2	3.8	0.0	5.1	0.6	1.0	1.0	1.4	43.4	8.7	13.7	1.5	37.5	31.9	42.5	6.9	39.7	24.0	2.6
PointDR ^[22]	23.4	57.2	2.8	0.0	16.5	3.1	6.0	7.5	29.3	62.3	8.4	23.2	4.8	50.7	42.5	46.8	10.0	43.1	22.1	8.5
PointDR* ^[22]	30.9	70.6	0.7	22.1	37.1	4.9	34.7	5.2	35.6	64.0	10.7	33.2	2.9	68.1	47.3	52.7	21.5	39.5	29.7	6.3
DGUIL ^[32]	32.2	69.9	0.1	16.9	8.4	6.7	43.8	1.3	39.9	60.5	9.2	32.0	0.9	73.8	43.3	59.4	36.4	52.0	30.2	28.1
SJ+LPD ^[20]	39.4	84.8	0.7	23.6	27.9	29.9	45.0	9.0	36.1	67.9	16.3	39.5	3.8	76.6	52.8	65.1	40.8	54.8	31.0	43.1
本文算法	40.5	85.3	8.4	28.3	43.4	26.2	56.5	20.2	50.1	68.1	10.3	38.7	4.9	77.0	50.1	57.5	36.6	45.6	32.4	35.3

与召回率之间的良好平衡。在精确率方面,所提算法表现尤为突出,达到了62.3%,高于其他方法,表明其在减少误检和提升目标识别准确度方面的显著优势。同时,召回率为53.0%,有效降低了漏检率,验证了该方法在复杂场景下的泛化性与适应能力。

表2 算法在精确率、召回率、F1值的性能对比

Table 2 Performance Comparison of Different Algorithms in Terms of Precision, Recall, and F1-Score

方法	精确率	召回率	F1值
基准模型 ^[27]	53.8	40.7	46.3
PolarMix ^[30]	27.5	32.5	29.8
LaserMix ^[31]	29.1	30.7	29.9
PointDR ^[22]	41.9	37.2	39.4
DGUIL ^[32]	42.8	39.7	41.2
SJ+LPD ^[20]	60.4	51.7	55.7
本文算法	62.3	53.0	57.3

表3对比了不同方法在四种恶劣天气条件下的性能。结果表明,本文算法在浓雾、薄雾和雪天三种场景下均取得了最优表现。具体而言,在“浓雾”和“薄雾”条件下,本文算法的性能分别达到37.0%和38.2%,显著证明了其在低能见度环境下的优越性。在雪天环境下,本文算法的表现同样超越了SJ+LPD。虽然在雨天场景下,本文算法略低于SJ+LPD,但这可能归因于SJ+LPD专门针对点云丢失进行了针对性建模,从而在强随机丢失场景下具备更强的泛化性。

表3 不同天气下算法性能对比

Table 3 Performance comparison of different methods under various weather conditions

方法	浓雾	薄雾	雨	雪
基准模型 ^[27]	36.0	30.5	29.2	19.6
PolarMix ^[30]	22.1	15.3	11.4	8.7
LaserMix ^[31]	21.8	16	12.5	7.8
PointDR ^[22]	33.5	21.1	23.1	16.7
DGUIL ^[32]	35.1	30.8	35.0	29.4
SJ+LPD ^[20]	34.7	37.5	37.5	33.7
本文算法	37.0	38.2	36.9	34.8

3.5.2 可视化结果

图4展示了各对比方法在恶劣天气场景(包括薄雾、浓雾、雨天和雪天)下的点云语义分割结果。其中,不同颜色代表不同的语义类别,红色圆圈突出了分割结果中存在明显错误或不一致的局部

区域。

从图4可以看出,在薄雾和浓雾场景(a-b)中,基线模型在远距离目标及稀疏区域易出现漏检与类别混淆;在雨雪场景(c-d)中,随机噪声和局部几何扰动导致其出现大面积误识别,局部结构的判别能力进一步削弱。SJ+LPD方法在一定程度上缓解了环境扰动带来的性能下降,整体预测结果较基线模型更加稳定,但在精细语义边界及远距离区域仍存在类别粘连和误判现象。相比之下,本文提出的方法在多种恶劣天气场景下均表现出更准确的分割效果。

3.5.3 消融实验结果

为了全面评估本文所提算法的有效性,我们在SemanticSTF数据集上进行了消融实验。具体而言,实验以基准模型为基础,逐步引入数据增强模块和基于退化特征的一致性学习模块,从而验证各个模块对模型性能的影响。实验结果如表4所示。

首先,基准模型在未引入任何额外模块的情况下,性能仅为29.8%。在此基础上,加入基于细粒度语义的实例增强模块后,模型的性能显著提升至36.3%。这一提升表明,局部数据增强方法通过增加实例的多样性,显著增强了模型对局部细节的学习能力,从而有效改善了分割精度。随后,引入基于空间分区的距离感知扰动方法,使得模型的性能进一步提高到38.7%。验证了该策略在模拟恶劣天气下数据失真的有效性。最后,加入基于退化特征的一致性学习模块,模型达到了40.5%的最优性能。

3.5.4 退化特征一致性机制分析

为分析退化特征一致性机制的作用,本节采用KL散度、预测一致率和退化分支预测熵,分别衡量良好特征与退化特征预测分布的差异、类别预测的一致程度以及退化状态下的预测不确定性。对于同一帧点云,分别基于原始体素特征和随机退化后的体素特征获得两种状态下的预测结果,并统计相应指标。对于未采用退化特征一致性学习的模型,在测试阶段施加相同的特征退化操作,以保证比较条件一致。

如表5所示,引入退化特征一致性学习后,KL散度由0.1626降低至0.0188,预测一致率由86.42%提升至96.80%,说明该模块能够有效降低特征退化引起的预测分布偏移,使模型在部分体素特征响应被抑制时仍保持稳定的类别判断。同时,预测熵由0.4953略降至0.4913,表明退化条件下模




图4 SemanticSTF验证集上3D语义分割的可视化结果对比

Fig. 4 Qualitative comparison of 3D semantic segmentation results on the SemanticSTF validation set

表4 消融实验结果

Table 4 Ablation experiment results

基准模型	数据增强模块		基于退化特征的一致性学习模块	mIoU
	基于细粒度语义的实例增强	基于空间分区的距离感知扰动		
✓				29.8
✓	✓			36.3
✓	✓		✓	38.7
✓	✓		✓	40.5

型预测不确定性未增加；mIoU从38.7%提升至40.5%，进一步说明该机制有助于提升恶劣天气场景下的语义分割性能。

表5 退化特征一致性机制分析

Table 5 Analysis of degraded feature consistency learning

评价指标	无退化特征一致性学习	有退化特征一致性学习
KL散度↓	0.1626	0.0188
预测一致性↑	86.42%	96.80%
预测熵↓	0.4953	0.4913
mIoU↑	38.7	40.5

3.5.5 参数敏感性分析

本节对一致性损失权重和特征丢弃概率进行了敏感性实验。实验结果如表6和表7所示。由表6可以看出,当一致性损失权重由0增大至0.5时,mIoU由38.7%提升至40.5%,说明适当的一致性约束有助于提升模型对特征退化的适应能力。当一致性损失权重继续增大至0.7和1.0时,mIoU分别下降至39.6%和37.8%,表明过强的一致性约束

可能会影响模型的语义判别能力。由表7可以看出,当特征丢弃概率为0.3时,模型取得40.5%的分割结果;当特征丢弃概率过小或过大时,模型性能均有所下降,说明退化强度不足或过强都不利于模型学习稳定的语义表示。因此,本文最终将一致性损失权重设置为0.5,将特征丢弃概率设置为0.3。

表6 一致性损失权重的敏感性分析

Table 6 Sensitivity Analysis of the Consistency Loss Weight

一致性损失权重	0	0.1	0.3	0.5	0.7	1.0
mIoU	38.7	38.8	39.2	40.5	39.6	37.8

表7 特征丢弃概率的敏感性分析

Table 7 Sensitivity Analysis of the Feature Dropout Probability

特征丢弃概率	0.1	0.2	0.3	0.4	0.5	0.7
mIoU	37.2	38.0	40.5	37.5	36.4	34.6

3.5.6 模型效率结果

为评估本文所提语义分割方法的综合效率,本节在 SemanticSTF 数据集上进行了实验。该数据集包含 250 个样本,样本平均点数约为 47 323。本实验以 5 次测试的平均推理时间作为运行效率指标,并统计各方法的模型参数量,对比结果如表 8 所示。

表 8 算法参数量以及效率对比

Table 8 Comparison of Model Parameters and Computational Efficiency

方法	参数量(百万)	平均推理时间(秒)
基准模型 ^[27]	21.72	16.01
PolarMix ^[30]	21.72	16.12
LaserMix ^[31]	21.72	16.98
PointDR ^[22]	5.46	13.13
DGUIL ^[32]	5.46	13.17
SJ+LPD ^[20]	21.76	16.15
本文算法	21.72	16.04

实验结果表明,PointDR 与 DGUIL 的参数量较小,且推理耗时接近(约为 13 秒),尽管 PointDR 推理速度略具优势,但 DGUIL 的分割精度(32.2%)远超 PointDR(23.4%),表现出更好的性能权衡。MinkUNet、SJ+LPD、PolarMix、LaserMix 以及本文方法在参数量与推理耗时(约 16 秒)上较为接近;尽管本文方法的推理速度略慢于 DGUIL,但其分割精度实现了 8.3% 的显著提升。

3.6 讨论

本文提出的恶劣天气下的基于退化特征一致性学习的三维语义分割方法,通过在数据增强与特征表示两个层面进行协同建模,在恶劣天气条件下显著提升了模型的泛化性及小目标类别的分割精度。然而,该方法在训练复杂性和适应范围方面仍存在一定局限。

首先,基于退化特征的一致性学习模块需要在高维体素特征上进行并行计算并对齐预测分布,相较于标准单分支训练框架,训练阶段的计算量与显存开销有所增加。尽管该开销主要集中于训练阶段,对推理效率影响较小,但在大规模训练或资源受限场景下仍可能带来一定限制。未来将探索更高效的特征退化建模与一致性约束机制,以进一步降低训练成本。

其次,本文的小目标类别增强与空间扰动策略

主要基于源域点云的特性构建。在实际道路环境中,恶劣天气的退化模式更加多样。未来工作将结合更大规模、多气象条件的数据以及物理一致的仿真建模,以进一步提升方法在恶劣天气下的适应性与稳定性。

4 结 论

针对恶劣天气条件下激光雷达采集的点云失真问题,主要包括点丢失、遮挡及几何扰动等现象,本文提出一种恶劣天气下基于退化特征一致性学习的点云语义分割方法。该方法从数据层与特征层两个维度协同建模,通过数据增强与特征空间一致性学习,在不引入目标域数据的前提下提高了恶劣天气下的分割性能。基于 SemanticSTF 公开数据集的实验,可以得到如下结论:

(1)通过构建由细粒度语义实例增强与空间分区距离感知扰动协同的数据增强模块,能够有效模拟雨、雪、雾等恶劣天气引发的点云失真。该模块增强了模型对点云结构变化的适应能力,使其在仅利用晴朗场景数据训练的前提下,仍能对数据失真现象保持稳健感知,从而显著提升整体分割性能。

(2)提出了一种基于退化特征的一致性学习机制。通过在体素特征空间构建“良好特征”分支与“退化特征”分支,并以“良好特征”分支的语义预测作为一致性监督,引导网络挖掘对特征受损不敏感的稳健空间与语义表征,使模型在 SemanticSTF 验证集上的性能达到 40.5%,优于现有方法。

(3)揭示了数据增强与特征空间一致性学习的协同作用。该策略使模型在数据层面学习数据失真的多样性,在特征层面学习表征的稳健性,从而在恶劣天气场景中实现了稳健的语义分割性能。

参考文献:

- [1] 朱安迪,达飞鹏,盖绍彦. 对融合特征敏感的三维点云识别与分割[J]. 西安交通大学学报, 2024, 58(5): 52-63.
Zhu Andi, Da Feipeng, Gai Shaoyan. Recognition and segmentation of 3D point clouds sensitive to fusion features [J]. Journal of Xi'an Jiaotong University, 2024, 58(5): 52-63.
- [2] 杨军,王连甲. 结合位置关系卷积与深度残差网络的三维点云识别与分割[J]. 西安交通大学学报, 2023, 57(5): 182-193.
Yang Jun, Wang Lianjia. Recognition and segmentation of 3D point cloud through positional

- relation convolution in combination with deep residual network [J]. Journal of Xi'an Jiaotong University, 2023, 57(5): 182-193.
- [3] 薛豆豆, 程英蕾, 文沛, 等. MLMS-Net: 多层次多尺度点云分类网络[J]. 西安交通大学学报, 2020, 54(12): 70-78.
Xue Doudou, Cheng Yinglei, Wen Pei, et al. MLMS-Net: a point cloud classification network with multi-level and multi-scale [J]. Journal of Xi'an Jiaotong University, 2020, 54(12): 70-78.
- [4] 李梢, 李垚辰, 张玉龙, 等. 采用稀疏3D卷积的单阶段点云三维目标检测方法[J]. 西安交通大学学报, 2022, 56(9): 112-122.
Li Qiao, Li Yaochen, Zhang Yulong, et al. A single-stage point cloud 3D object detection method using sparse 3D convolution [J]. Journal of Xi'an Jiaotong University, 2022, 56(9): 112-122.
- [5] 仇志江, 张林, 姚垚, 等. 三维点云场景语义分割研究进展[J]. 中国图象图形学报, 2025, 30(7): 2325-2342.
Qiu Zhijiang, Zhang Lin, Yao Yao, et al. Survey on semantic segmentation in 3D point cloud scenes [J]. Journal of Image and Graphics, 2025, 30(7): 2325-2342.
- [6] 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 Yutian, Li Qing, Sun Wenwei, 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.
- [7] 李佳乐. 面向自动驾驶的三维点云语义分割关键技术研究[D]. 杭州: 浙江大学, 2023.
- [8] Zhao Haimei, Zhang Jing, Chen Zhuo, et al. UniMix: towards domain adaptive and generalizable LiDAR semantic segmentation in adverse weather [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2024: 14781-14791.
- [9] Singhal P, Walambe R, Ramanna S, et al. Domain adaptation: challenges, methods, datasets, and applications[J]. IEEE Access, 2023, 11: 6973-7020.
- [10] Zhou Kaiyang, Liu Ziwei, Qiao Yu, et al. Domain generalization: a survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(4): 4396-4415.
- [11] 范文辉, 林茜, 罗欢, 等. 面向三维点云的域自适应学习[J]. 遥感学报, 2024, 28(4): 825-842.
Fan Wenhui, Lin Xi, Luo Huan, et al. Domain adaptation learning for 3D point clouds: a survey [J]. National Remote Sensing Bulletin, 2024, 28(4): 825-842.
- [12] Jiang Peng, Saripalli S. LiDARNet: a boundary-aware domain adaptation model for point cloud semantic segmentation [C]//2021 IEEE International Conference on Robotics and Automation (ICRA). Piscataway, NJ, USA: IEEE, 2021: 2457-2464.
- [13] Yuan Zhimin, Wen Chenglu, Cheng Ming, et al. Category-level adversaries for outdoor LiDAR point clouds cross-domain semantic segmentation [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(2): 1982-1993.
- [14] Muandet K, Balduzzi D, Schölkopf B. Domain generalization via invariant feature representation [C]//Proceedings of the 30th International Conference on Machine Learning. Chia Laguna Resort, Sardinia, Italy: PMLR, 2013: 10-18.
- [15] Balaji Y, Sankaranarayanan S, Chellappa R. MetaReg: towards domain generalization using meta-regularization [C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Piscataway, NJ, USA: IEEE, 2018: 1006-1016.
- [16] Li Haoliang, Pan S J, Wang Shiqi, et al. Domain generalization with adversarial feature learning [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 5400-5409.
- [17] Huang Jiaxing, Guan Dayan, Xiao Aoran, et al. FSDR: frequency space domain randomization for domain generalization [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 6887-6898.
- [18] Huang Chao, Cao Zhangjie, Wang Yunbo, et al. MetaSets: meta-learning on point sets for generalizable representations [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 8859-8868.
- [19] Huang Hao, Chen Cheng, Fang Yi. Manifold adversarial learning for cross-domain 3D shape representation [C]//Computer Vision - ECCV 2022. Cham: Springer Nature Switzerland, 2022: 272-289.
- [20] Park J, Kim K, Shim H. Rethinking data augmentation for robust LiDAR semantic segmentation in adverse weather [C]//Computer Vision - ECCV 2024.

- Cham: Springer Nature Switzerland, 2025: 320-336.
- [21] Park J, Lee H, Kang I, et al. No thing, nothing: highlighting safety-critical classes for robust LiDAR semantic segmentation in adverse weather [C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2025: 6690-6699.
- [22] Xiao A, Huang J, Xuan W, et al. 3D semantic segmentation in the wild: learning generalized models for adverse-condition point clouds [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2023: 9382-9392.
- [23] Tarvainen A, Valpola H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 1195-1204.
- [24] Liu Yuanan, Tian Yu, Chen Yuanhong, et al. Perturbed and strict mean teachers for semi-supervised semantic segmentation [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 4248-4257.
- [25] Wu Yushuang, Yan Zizheng, Cai Shengcai, et al. PointMatch: a consistency training framework for weakly supervised semantic segmentation of 3D point clouds [J]. Computers & Graphics, 2023, 116: 427-436.
- [26] Wu Zhonghua, Wu Yicheng, Lin Guosheng, et al. Reliability-adaptive consistency regularization for weakly-supervised point cloud segmentation [J]. International Journal of Computer Vision, 2024, 132 (6): 2276-2289.
- [27] Choy C, Gwak J Y, Savarese S. 4D spatio-temporal ConvNets: minkowski convolutional neural networks [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 3070-3079.
- [28] van Erven T, Harremos P. Rényi divergence and Kullback-Leibler divergence [J]. IEEE Transactions on Information Theory, 2014, 60(7): 3797-3820.
- [29] Behley J, Garbade M, Milioto A, et al. SemanticKITTI: a dataset for semantic scene understanding of LiDAR sequences [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2019: 9296-9306.
- [30] Xiao Aoran, Huang Jiaxing, Guan Dayan, et al. PolarMix: a general data augmentation technique for LiDAR point clouds [C]//Proceedings of the 36th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2022: 11035-11048.
- [31] Kong Lingdong, Ren Jiawei, Pan Liang, et al. LaserMix for semi-supervised LiDAR semantic segmentation [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 21706-21716.
- [32] He Pei, Jiao Licheng, Li Lingling, et al. Domain generalization-aware uncertainty introspective learning for 3D point clouds segmentation [C]//Proceedings of the 32nd ACM International Conference on Multimedia. New York, NY, USA: Association for Computing Machinery, 2024: 651-660.
- (编辑 曹康莹 杜秀杰)