研究论文|Research Article
时空智能|Spatio-Temporal Intelligence

引用格式:赖启印, 方莉娜. 联合边界引导和多尺度特征的路侧交通地物点云感知 [J]. 海南大学学报(自然科学版中英文), 2026, 44(4): 387−401.

Citation: Lai Qiyin, Fang Lina. Roadside traffic object point cloud perception with joint boundary guidance and multi-scale features[J]. Natural Science of Hainan University, 2026, 44(4): 387−401.

Open Access

联合边界引导和多尺度特征的路侧交通地物点云感知

赖启印[1,2,3], 方莉娜[1,2,3] ✉

(1. 福州大学 数字中国研究院(福建), 福建 福州 350108; 2. 空间数据挖掘与信息共享教育部重点实验室, 福建 福州 350108; 3. 地理空间信息技术国家地方联合工程研究中心, 福建 福州 350108)

摘　要: 针对复杂城市场景中路侧交通地物形态多样、边界模糊且易受遮挡, 导致点云感知精度不稳定的问题, 提出了一种面向路侧交通地物精确感知的新方法。该方法通过在点云特征学习过程中引入边界约束, 减少不同地物之间的相互干扰, 并结合多尺度信息融合策略, 同时兼顾局部细节与整体结构, 从而提升在复杂道路环境中的识别能力。实验采用 3 份不同车载激光扫描系统获取的不同城市场景数据来验证本方法的有效性。结果表明, 所提模型在 3 组数据上的平均交并比和路侧交通地物交并比分别达到 89.48% 和 87.91%, 并在快速路、主干路、次干路和支路等不同道路类型中分别取得 94.90%、93.36%、90.14% 和 88.56% 的路侧交通地物交并比。该方法在多种道路场景下均能够稳定提升路侧交通地物的识别精度, 尤其在地物密集、遮挡严重的城市街道环境中表现出更强的鲁棒性与泛化能力。研究结果可为推动交通基础设施数字化转型提供数据基础。

关键词: 路侧交通地物; 车载激光扫描系统; 边界引导; 多尺度特征融合; 鲁棒性

中图分类号: P237　　**文献标志码:** A　　**文章编号:** 1004-1729(2026)04-0387-15

DOI: 10.65658/j.hndk.2026022801　　CSTR: 32403.14.hndk.2026022801

Roadside traffic object point cloud perception with joint boundary guidance and multi-scale features

Lai Qiyin[1,2,3], Fang Lina[1,2,3] ✉

(1. Academy of Digital China, Fuzhou University, Fuzhou 350108, China;
2. Key Lab of Spatial Data Mining and Information Sharing, Ministry of Education, Fuzhou 350108, China;
3. National Engineering Research Center of Geospatial Information Technology, Fuzhou 350108, China)

Abstract: To address the problem of unstable point cloud perception accuracy caused by the diverse forms,blurred bound aries and high susceptibility to occlusions of roadside traffic objects in complex urban environments,this paper proposes a novel method for precise perception of roadside traffic objects. By introducing boundary constraints into the point cloud feature learning process, the proposed method effectively mitigates interference among different object categories. Meanwhile, a multi-scale feature fusion strategy is incorporated to jointly capture local details and global structural information, thereby enhancing recognition

Received: 2026−02−28; **Revised:** 2026−03−10; **Accepted:** 2026−03−11.
✉ **Corresponding author(s):** Fang Lina, E-mail:fangln@fzu.edu.cn.

performance in complex road scenarios. Experiments are conducted on three datasets collected from different urban scenes using vehicle-mounted LiDAR systems to validate the effectiveness of the proposed approach. The results demonstrate that the proposed model achieves a mean Intersection over Union (mIoU) of 89.48% and a roadside traffic object IoU of 87.91% across the three datasets. Furthermore, the method attains IoU scores of 94.90%, 93.36%, 90.14%, and 88.56% for roadside traffic objects on expressways, arterial roads, secondary trunk roads, and branch roads, respectively. Overall, the proposed method consistently improves the recognition accuracy of roadside traffic objects across diverse road environments, exhibiting strong robustness and generalization capability, particularly in densely populated and heavily occluded urban street scenes. The findings of this study provide a reliable data foundation for advancing the digital transformation of transportation infrastructure.

Keywords: roadside traffic objects; mobile laser scanning systems; boundary guidance; multi-scale feature fusion; robustness

0 引 言

随着交通运输行业的发展,道路场景中海量交通基础设施的高效管理与精细化维护面临着更高要求。路灯和交通标志牌等典型路侧交通地物,在维持交通秩序、提升通行效率以及保障道路交通安全方面具有重要意义。因此,如何快速、准确地获取此类地物的三维空间信息、语义类别及其属性数据,成为推动交通基础设施数字化转型的关键[1−2]。车载激光扫描系统(mobile laser systems, MLS)作为测绘领域的重要技术,能够高效、精准地获取道路两侧交通基础设施和树木等目标的三维点云数据,为大范围路侧交通地物的感知提供有力的数据支撑[3−5]。

车载激光点云数据具有海量性和非规则结构特征,为数据处理与特征提取带来了较大挑战。同时,城市道路场景中的路侧地物类型多样,尺度差异显著,且常伴随交叠与遮挡等复杂情况,使得路侧交通地物感知任务存在难点[6]。一些学者通过结合点云的几何属性约束[7−9]和统计信息规则[10−12],来构建上下文语义信息,并利用决策树[13]、支持向量机(support vector machine, SVM)[14]和模板匹配[15]等分类器实现路侧交通地物的区分。这些方法为路侧交通地物的智能化感知迈出了重要一步。然而,由于这些方法依赖于特征计算单元的选择和人工设计的特征描述符,其在实际应用中难以推广。

近年来,深度学习凭借强大的特征表示和学习能力,在路侧交通地物智能化感知领域得到了广泛应用。Qi 等[16]首次提出了直接处理原始点云数据的网络结构 PointNet,通过共享多层感知机(multi-layers perceptron, MLP)对点进行独立特征提取,并利用对称函数实现全局特征聚合,有效解决了点云无序性的问题,为点云深度学习奠定了基础。Wang 等[17]进一步引入动态图卷积机制提出了 DGCNN,通过在特征空间构建并动态更新 K 近邻图,增强了模型对局部几何结构的表达能力。Thomas 等[18]提出一种核点卷积(kernel point convolution, KPConv),通过预定义一组核心点并计算输入点云与核心点之间的关系,实现一种适应点云数据特点的卷积操作,在大规模点云场景分割中表现出良好效果。Hu 等[19]提出了一种高效且轻量级的网络架构 RandLANet,结合随机采样和局部特征聚合模块,平衡了大规模场景点云分割时网络的效率和性能,但其全局特征表现不足。在 RandLANet 的基础上,Fan 等[20]提出了可学习更多空间上下文信息的 SCFNet。鉴于 Transformer 架构的强大性能,一些学者将自注意力机制引入到点云数据处理[21],通过融合全局与局部信息,提升了点云感知的精度与鲁棒性。

现有点云深度学习方法虽然能够有效学习点云的空间特征,在语义分割任务中取得了较好的效果,但在复杂道路场景中仍然面临两个关键问题。一方面,复杂城市场景中路侧交通地物常与行道树等目标发生遮挡或粘连,不同类别点在空间上高度交错。当网络在局部邻域中提取特征时,容易混合来自不同类别的点特征,导致目标边界信息逐渐模糊,并在深层特征传播过程中不断累积,从而影响分割结果的准

确性。另一方面，路灯、交通信号灯、交通标志牌及电子监控等路侧交通地物在形态结构与空间尺度上存在显著差异，若仅依赖单一尺度特征进行建模，往往难以同时兼顾局部几何细节与整体结构信息，进而影响模型对不同类型地物的感知能力。

针对上述问题，本文提出一种联合边界引导和多尺度特征融合的路侧交通地物感知（boundary-guided and multi-scale feature fusion network, BG-MSNet）模型。该模型基于 U-Net 网络架构，通过在特征编码早期引入边界约束，减少跨类别特征混合，同时受到多尺度特征融合机制的启发，在解码阶段融合深层与浅层的语义信息，增强网络对不同尺寸地物的表达能力，从而提升复杂道路场景下路侧交通地物的分割精度。

1 路侧交通地物感知模型

为了在复杂的道路场景中有效获取路侧交通地物的信息，基于编码器−解码器架构，构建路侧交通地物感知模型 BG-MSNet，如图 1 所示。模型输出为每个点的类别标签，模型整体框架包括 3 个主要模块：输入特征增强模块（feature augmentation, FA）模块、边界引导几何编码模块（boundary-aware geometric encoding module, BGEM）和多尺度特征自适应融合模块（multi-scale feature adaptive fusion module, MFAFM）。

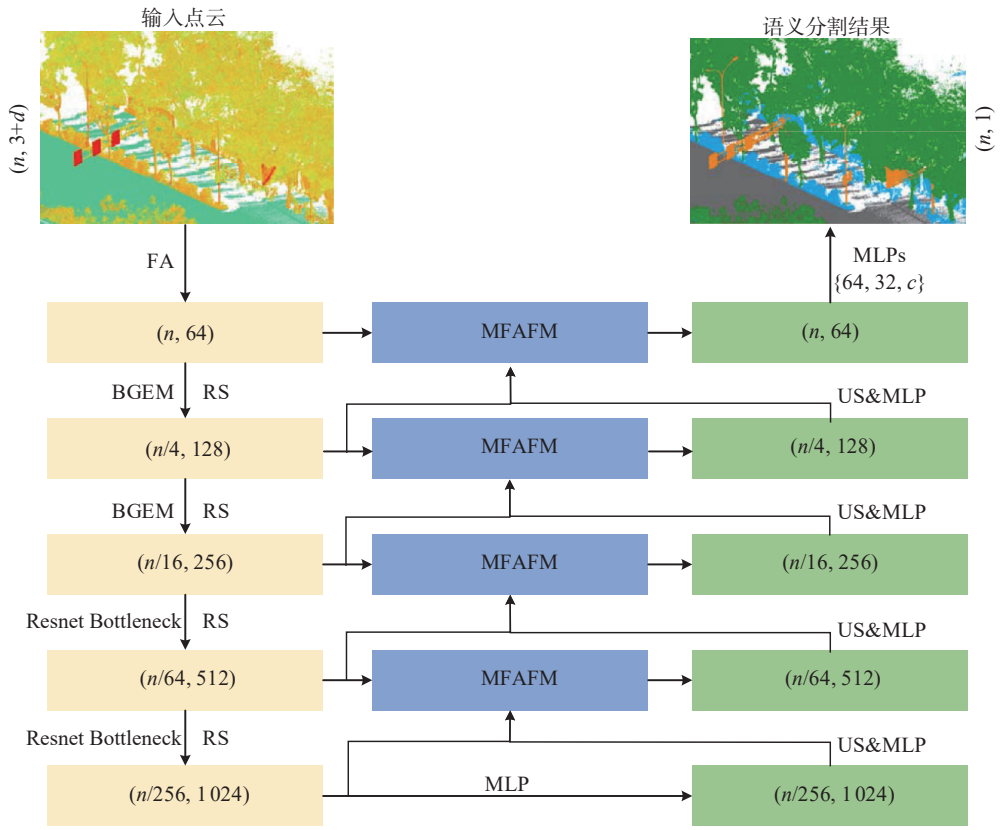


图 1 BG-MSNet 整体网络结构

注：n 为模型输入点云数量，$3+d$ 为输入点云的特征维度，RS 为随机下采样，Restnet Bottleneck 为残差卷积模块，US 为最近邻插值上采样，c 为模型预测的类别数量。

1.1 输入特征增强 植被指数通过多光谱组合能够有效表征植被信息和植被活力，准确的植被指数计算和阈值选取能够有效地区分植被与非植被地物。经典的植被指数（如归一化植被指数和增强型植被指数等）普遍依赖于可见光波段与近红外波段的协同观测，汪小钦等[22]针对可见光波段，通过分析绿色植被和典型地物的光谱反射特性，提出了可见光波段植被差异指数（visible-band difference vegetation index, VDVI），为部分只能获取可见光波段的车载激光雷达系统提供了更丰富、有效的行道树分割判别依据。具体如式（1）所示。

$$I_{\mathrm{VDVI}}=\frac{2\rho_{\mathrm{green}}-(\rho_{\mathrm{red}}+\rho_{\mathrm{blue}})}{2\rho_{\mathrm{green}}+(\rho_{\mathrm{red}}+\rho_{\mathrm{blue}})} \tag{1}$$

式中，I_{VDVI}为光波段植被差异指数，取值范围为 [−1,1]；ρ_{red}、ρ_{green}和ρ_{blue}分别为可见光波段中的红波段、绿波段和蓝波段的反射率。

点云粗糙度是描述点云局部范围内不规则性或不光滑程度的一个重要指标，能够有效表达点云局部的形态特征[23]。点云粗糙度可以通过式(2)来计算。

$$R(p_i)=\frac{1}{|N(p_i)|}\sum_{p_j\in N(p_i)}\left|z_i-z_j\right| \tag{2}$$

式中，$R(p_i)$为点云粗糙度；$N(p_i)$为以点p_i为中心，半径为 0.25 的邻域点集合；p_j为点p_i的邻域点；z_i和z_j分别为点p_i和p_j的高度值。

由于路侧交通地物通常为人造地物，表面较为光滑且规则，而行道树作为自然生长地物，其树干表面通常较为粗糙，且树叶的分布和形态增加了点云表面的不规则性。因此，点云粗糙度能够有效区分路侧交通地物与行道树。

首先利用车载激光点云数据中的光谱信息构建适应性的可见光波段差异植被指数，结合点云的几何信息计算点云粗糙度，以此构建几何特征。然后将点云的空间三维坐标、VDVI 的光谱判别特征以及点云粗糙度几何特征作为模型的输入特征，通过可学习权重的动态关联，从而增强行道树与路侧交通地物之间的可区分特征，提高路侧交通地物的精确感知能力。

1.2 边界引导几何编码模块 边界是指属于不同类别的两个或多个对象之间的过渡区域，边界信息在点云语义分割中起着重要作用，通过边界信息的约束可以有效防止边界点附近的错误分类[24]。在道路场景中，路侧交通地物常与行道树和绿化带等目标在空间上高度邻近，点云层面普遍存在交错、粘连甚至局部重叠的现象，使得仅依赖常规局部特征聚合机制的分割模型难以获得稳定且精确的判别结果。针对该问题，在编码器的前两层引入边界引导几何编码模块，其中包括预训练边界预测模块和基于边界的特征聚合模块，如图 2 所示。

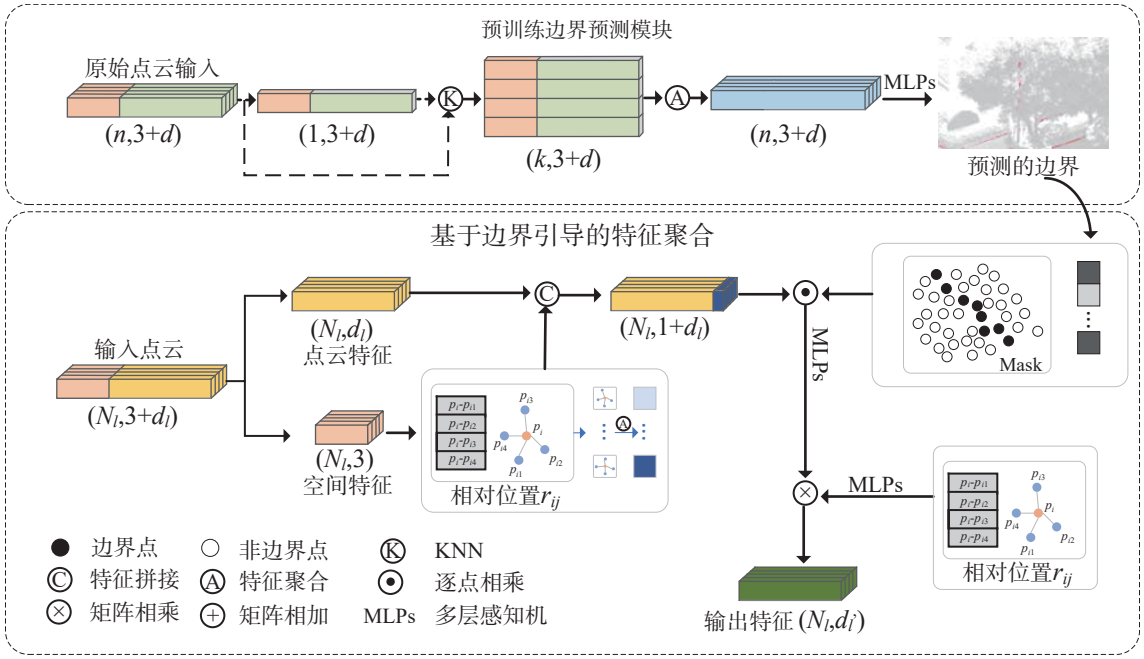


图 2 边界引导几何编码模块

注：k 为最近邻点的数量，N_l 为第 l 层点的数量，d_l 为第 l 层点的特征维度，不同 p 为点 p_i 及其邻域点，r_{ij} 为相对位置。

在编码器的后两层则仍采用经典的 Resnet Bottleneck 模块[25]进行特征提取，此设计实现从局部边界

约束到全局特征表达的有机融合，使网络在编码早期阶段能够有效防止类别特征混叠，同时在深层阶段保持对整体场景的全局感知能力，从而显著提升复杂道路场景中交错粘连地物的分割精度与鲁棒性。

1.2.1 预训练边界预测模块 边界信息的可靠获取是边界引导编码机制有效发挥作用的前提，为获取准确有效的边界信息，在原始点云数据上预先构建并训练一个边界预测模块对边界进行软预测。考虑到边界预测需要关注局部区域内语义信息的差异，对于采样点p_i，获取局部邻域内k个最近邻的特征，形成局部邻域特征集合$\mathcal{N}(p_i)=\{f_{i1},f_{i2},\ldots,f_{ik}\}$，并选取特征方差作为边界敏感描述，其计算如式(3)所示。

$$\boldsymbol{v}_i=\frac{1}{k}\sum_{j=1}^{k}(f_{ij}-f_i)^2 \tag{3}$$

式中，$\boldsymbol{v}_i$为点p_i在其局部邻域内的特征方差向量，k为最近邻点的数量，f_{ij}为邻域点p_{ij}的几何特征，f_i为点p_i的几何特征。

在此基础上，将上述局部方差特征输入由多个 MLP 组成的预测网络，对每个点独立进行非线性映射，最终输出对应的边界预测结果$\widehat{g}_i$。其计算公式如式(4)所示。

$$\widehat{g}_i=\sigma(\mathrm{MLP}(\boldsymbol{v}_i)) \tag{4}$$

式中，MLP(·)表示共享权重的多层感知机网络，$\sigma(\cdot)$为 Sigmoid 激活函数。

同时，在训练阶段，参照文献 [24] 中的方法，通过动态生成真实边界标签对边界预测模块进行监督。具体而言，将最近邻点的数量k设置为 32，若点p_i的固定数量邻域$\mathcal{N}(p_i)$中，超过 40% 的点与p_i不属于同一语义类别，则将其判定为边界点，否则视为非边界点。基于此定义，构建如式(5)所示的加权二值交叉熵损失函数。

$$\mathcal{L}_B=-\sum_{i=1}^{k}(w_1\cdot g_i\cdot \lg\hat{g}_i+w_2\cdot(1-g_i)\cdot\lg(1-\hat{g}_i)) \tag{5}$$

式中，$\mathcal{L}_B$为边界预测模块训练的损失函数；g_i为真实边界标签，$g_i\in[0,1]$(边界点取 0，非边界点取 1)；w_1和w_2为类别平衡权重，用于缓解边界点与非边界点数量不均衡的问题。

1.2.2 基于边界的特征聚合 在获得边界预测结果后，为了将其有效融入特征聚合过程，确保在编码过程的早期不同类别所属的局部特征不会相互干扰。图 2 中，当对某一非边界点(灰点)进行局部特征聚合时，对位于边界上的点(红点)施加抑制，可以避免跨类别特征的无约束传播。具体而言，点p_i的局部特征聚合过程可表示为

$$f_{\mathrm{local}}=\sigma\left(A\left(\{\varnothing(r_{ij})\cdot\mathrm{MLP}\left(\hat{g}_j\cdot f_{p_j}\right)\}\right)\right),\forall p_j\in\mathcal{N}(p_i) \tag{6}$$

式中，f_{local}为编码器前两层的特征；σ为 Sigmoid 激活函数；A 为通过矩阵乘法实现的聚合函数；$\varnothing$为另外几个独立的多层感知机，用于从点p_i和邻域点p_j的相对位置r_{ij}中学习邻域点p_j的权重；$\mathcal{N}(p_i)$为p_i的邻域；f_{p_j}为邻域点p_j的特征，包括原始特征和几何特征；$\hat{g}_j$为点p_i的邻域点p_j的边界预测结果，当p_j位于预测的边界上时，其对应的$\hat{g}_i=0$，从而在聚合过程中几乎不对局部特征产生贡献。

通过上述机制，在编码早期阶段有效阻断了边界点特征向非边界区域的传播，显著降低了信息跨边界扩散所带来的干扰风险，同时以较低的计算开销持续发挥作用。随着网络逐渐加深，点云数量不断减少，不同物体之间的全局语义关系变得愈发重要。在这一阶段，若继续对边界信息施加强约束，反而可能削弱整体场景建模能力。因此，在编码器后期阶段，采用不受边界限制的特征聚合方式以提取全局特征，其形式如式(7)所示。

$$f_{\mathrm{global}}=\sigma\left(A\left(\{\varnothing(r_{ij})\cdot\mathrm{MLP}(f_{p_j})\}\right)\right),\forall p_j\in\mathcal{N}(p_i) \tag{7}$$

式中，f_{global}为编码器后两层的特征。

当点数较少时，全局特征得以在不同物体之间自由传播，有助于模型更全面地捕获道路场景中的上下文关系，为后续解码阶段的精细分割提供更加一致且稳定的高层语义表示。

1.3 多尺度特征自适应融合模块 在道路场景中,路侧交通地物和行道树在点云数据中展现出多样的形态和尺寸。例如,路侧交通地物包括尺寸和高度各异的路灯、信号灯杆等;行道树从细小树枝到粗壮树干形状各异。单一尺度的模型在处理这类地物语义分割任务时,难以全面兼顾这些多样化的地物特征。在经典的编码器-解码器网络架构中,浅层特征保留丰富细节信息,但感受野小、语义信息匮乏,语义一致性欠佳;深层特征感受野大,语义一致性强,能编码精确语义信息,却缺少足够空间信息。直接融合深层和浅层特征会导致模型在复杂场景下的分割性能显著下降。因此,为了减小不同尺度特征在语义上的差异并增强特征融合的效果,借鉴多尺度特征融合机制[26],在解码器部分构建了多尺度特征自适应融合模块,利用来自编码器的多层特征来增强解码器特征的区分能力,将$F_{\mathrm{e}}^{l}\in\mathbf{R}^{N_l\cdot D_l}$表示为编码器第$l$层($l\in\{0,1,2,3,4\}$)的特征,其中$N_l$与$D_l$分别表示该层的点数与特征维度;与$F_{\mathrm{e}}^{l}$对应的解码器第$l$层特征表示为$F_{\mathrm{d}}^{l}\in\mathbf{R}^{N_l\cdot D_l}$。如图3所示。

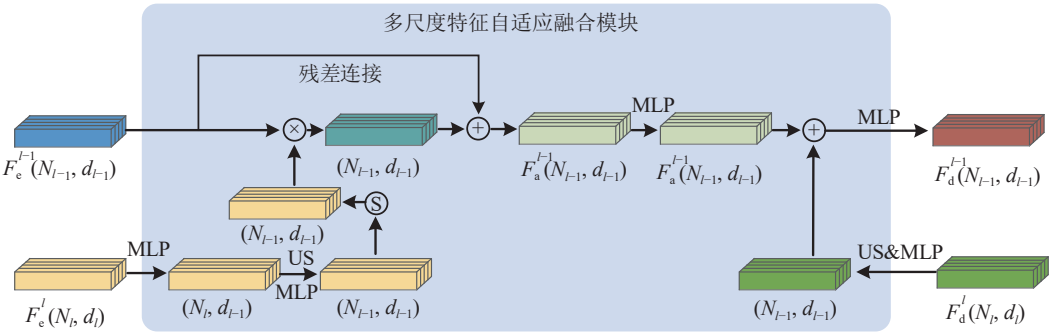


图3 多尺度特征自适应融合模块

注:F_{e}^{l-1}为编码器第l–1层特征,F_{a}^{l-1}为编码器第l层和编码器第l–1层之间的调制特征,F_{d}^{l}为解码器第l层特征,F_{d}^{l-1}为解码器第l–1层特征,N_l为第l层点的数量,N_{l-1}为第l–1层点的数量,d_l为第l层点的特征维度,d_{l-1}为第l–1层点的特征维度,Softmax为激活函数。

为增强解码器$l-1$层中特征F_{d}^{l-1}的表达能力,利用来自编码器相邻层的特征F_{e}^{l-1}和F_{e}^{l}进行联合调制。首先,对F_{e}^{l}采用最近邻插值上采样操作和一个共享的MLP来对齐F_{e}^{l-1}和F_{e}^{l}的点数量和特征维度。然后,通过另一组共享MLP并结合 Sigmoid 激活函数生成逐点注意力权重,用以刻画当前尺度下编码器特征对上一层编码器特征的贡献程度。最后,通过逐点乘法用该注意力图调制F_{e}^{l-1}。为了更好地融合这两个特征,使用残差连接来保留更多的低层线索,可表示为

$$F_{\mathrm{a}}^{l-1}=F_{\mathrm{e}}^{l-1}+F_{\mathrm{e}}^{l}\cdot\sigma(\mathrm{US}(\mathrm{MLP}(F_{\mathrm{e}}^{l}))) \tag{8}$$

式中,F_{a}^{l-1}为编码器第l层和编码器第$l-1$层之间的调制特征,F_{e}^{l}为解码器第l层特征,F_{e}^{l-1}为编码器第$l-1$层特征,σ为一个共享的MLP后接 Sigmoid 函数,US表示最近邻插值上采样。

多尺度特征融合捕捉多尺度信息,并且采用残差连接来保留低层细节。为了进一步减弱空间不可区分性的影响,通过一个简单的共享MLP来增强中间特征。最后,将调制后的编码器特征与解码器特征进行融合。这种多尺度特征融合机制可表示为

$$F_{\mathrm{d}}^{l-1}=\begin{cases}\mathrm{MLP}(F_{\mathrm{d}}^{l}), & \text{if } l=0\\ \mathrm{MLP}(F_{\mathrm{a}}^{l-1}), & \text{if } l=4\\ \mathrm{MLP}(\mathrm{MLP}(F_{\mathrm{a}}^{l-1}))+\mathrm{MLP}(\mathrm{US}(F_{\mathrm{d}}^{l})), & \text{其他}\end{cases} \tag{9}$$

经过优化后的深层特征F_{d}^{l-1}整合了多尺度信息,其语义表达更为丰富、准确,能够更好地实现尺度差异较大的路侧交通地物的分割。

1.4 损失函数 在城市道路场景中,行道树数量远超路侧交通地物,同时二者在空间位置上相邻交织,直接采用标准的交叉熵损失函数[27]来训练 BG-MSNet 模型易导致严重的类别不平衡问题,无法准确分割点数较少的路侧交通地物。因此,组合类别加权交叉熵损失函数[28]和对比边界损失函数[29]来构建整体损失函数,具体公式为

$$L_{\mathrm{c}}=\sum_{i=1}^{C}\frac{N}{N_i}l_i\lg(e_i) \tag{10}$$

$$L_B=\frac{-1}{|B_l|}\sum_{p_i\in B_l}\lg\frac{\sum\limits_{p_j\in K_i\cap l_j=l_i}\exp\left(-\dfrac{d(f_i,f_j)}{\tau}\right)}{\sum\limits_{p_{\mathrm{k}}\in K_i}\exp\left(-\dfrac{d(f_i,f_{\mathrm{k}})}{\tau}\right)}\Bigg| B_l=\{p_i\in P|\exists p_j\in K_i,l_j\neq l_i\} \tag{11}$$

$$L=\lambda L_C+(1-\lambda)L_B \tag{12}$$

式中，L_{c}为类别加权交叉熵损失函数；N_i为训练阶段第i类地物的点云数量；N为训练数据集中所有类别的点云总数；C为类别总数；l_i和e_i分别为点p_i的真实类别标签以及对应的预测类别标签；L_B为对比边界损失函数；B_l为真实边界标签；K_i为以点p_i为中心、半径为0.1的球形邻域；p_j为球形邻域内且与点p_i类别相同的点；l_j为点p_j的真实类别标签；f_i为点p_i的特征，f_j为点p_j的特征，f_{k}为点p_{k}的特征；$d(,)$为特征距离；τ为温度超参数，影响损失函数对相似度高的异类样本点云的关注程度；P为输入点集，p_{k}为点p_i邻域范围内的所有点；L为组合损失函数；λ为组合损失函数的权重参数，取值范围为[0,1]。

2 实验与分析

2.1 实验数据 为验证BG-MSNet模型在复杂道路环境中对路侧交通地物的感知能力，选取3份具有代表性的车载激光点云数据集开展实验。3类数据均包含路灯、交通标志牌和交通信号灯等典型目标，但在道路结构、遮挡程度及地物分布形态上差异明显，能够有效支撑对模型泛化性与鲁棒性的评估。金山数据集（实验数据Ⅰ）由厦门大学与福州大学于2020年在福州市中心城区采集，采用REGEL-VMX450车载激光扫描系统获取，覆盖主干道、次干道及居民区等多种城市道路场景。受道路宽度大、交通流密集等因素影响，点云中遮挡与缺失现象较为突出，路侧交通地物内部同时包含路灯、路牌和电线杆等几何形态差异显著的目标，语义边界模糊问题尤为明显。该数据集在统一标准下进行逐点人工标注，并划分为地面、路侧交通地物、行道树和其他4类，适用于验证模型在真实复杂城市场景中的分割能力。为进一步检验方法的通用性，引入公开数据集Toronto-3D[30]（实验数据Ⅱ）与Paris-Lille-3D[31]（实验数据Ⅲ）。Toronto-3D覆盖约1 km道路，包含近1×10^7个点，路侧交通地物、公用线路与行道树混合严重，同时存在车辆扫描伪影，对精细语义分割提出了较高要求。Paris-Lille-3D覆盖巴黎与里尔地区近2 km道路，点云规模更大，场景中建筑、行道树与栅栏频繁交叠，路侧交通地物与护桩形态接近，仅在高度上存在差异。上述数据集共同构成了贴近实际应用的测试环境，为评估BG-MSNet模型在复杂路侧交通地物感知任务中的有效性提供了坚实基础。3份实验数据的基本信息见表1，空间分布情况如图4所示。

表1 实验数据基本信息

数据集	地理位置	数据场景	扫描系统	道路长度/km	各类别点数/×10⁶个			
					路侧交通地物	行道树	路面	其他
实验数据Ⅰ	中国福州	复杂城区街道	RIGEL VMX-450	45	18.76	1 054.22	1 013.73	816.27
实验数据Ⅱ	加拿大多伦多	城区街道	Teledyne Optech Maverick	1	0.15	1.92	6.60	1.60
实验数据Ⅲ	法国巴黎	城区街道	Velodyne HDL-32E	2	0.35	3.46	34.92	21.30

2.2 实验参数设置与评价指标 BG-MSNet模型在配备GeForce RTX 4 080 16 GiB显卡、Python 3.6、CUDA 12.1和TensorFlow GPU 1.15的计算环境中运行。在模型训练阶段，采用随机梯度下降（stochastic gradient descent,SGD）和自适应动量优化器（adaptive moment estimation,Adam）两种优化方法。综合考虑训练精度和时间效率，将输入模型点云数量设为65 536，批量大小设为4，初始学习率设为0.01，衰减率和动量分别设为0.95和0.9，训练轮次设为100，如图5所示。经实验验证，损失函数的权重λ为0.8时，路侧交

通地物感知能力最优。因此损失函数的权重λ均设置为0.8。



图4 实验数据空间分布

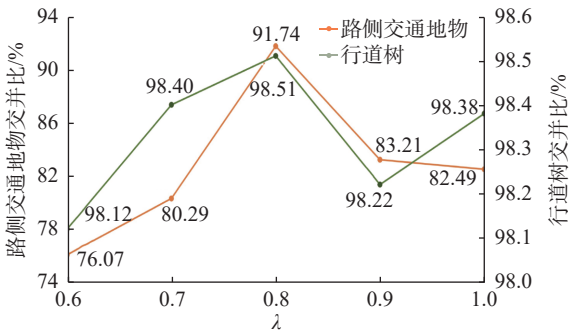


图5 不同损失函数权重λ模型精度对比

在网络结构层面,BG-MSNet模型的编码器由4层特征编码模块堆叠而成,用于逐级提取点云的空间与语义特征。每一层编码模块后均执行随机下采样操作,其采样率依次设为{0.25,0.25,0.25,0.5}。该设计使得点云规模随网络深度逐渐压缩,在控制计算复杂度的同时保留关键结构信息,从而在特征表达能力与训练效率之间取得平衡。与编码器形成对称结构的解码器,则在特征重建阶段采用与之相对应的上采样策略,通过逐层恢复空间分辨率,将高层语义信息逐步映射回稠密点云表示。

为客观评估BG-MSNet模型在行道树与路侧交通地物提取任务中的性能,选取总体精度(overall accuracy, OA)、交并比(intersection over union, IoU)以及平均交并比(mean intersection over union,mIoU)作为评价指标,即

$$A_{\mathrm{OA}}=\frac{P_{\mathrm{TP}}}{P_{\mathrm{TP}}+P_{\mathrm{FP}}}\times 100\% \tag{13}$$

$$I_{\mathrm{IoU}}=\frac{P_{\mathrm{TP}}}{P_{\mathrm{TP}}+P_{\mathrm{FP}}+N_{\mathrm{FP}}}\times 100\% \tag{14}$$

$$m_{\mathrm{mIoU}}=\sum_{i=0}^{N_{\mathrm{c}}} I_{\mathrm{IoU}i} \tag{15}$$

式中,A_{OA}表示总体精度,I_{IoU}表示交并比,m_{mIoU}表示平均交并比,P_{TP}表示正确识别的正样本数量;P_{FP}表示错误识别的正样本数量;N_{FP}表示错误识别的负样本数量;N_{c}表示类别总数。

2.3 不同道路场景实验结果 为系统评估BG-MSNet模型在多样化道路环境中对路侧交通地物的感知与分割能力,结合OpenStreetMap的路网数据,对金山数据集按照道路功能等级划分为快速路、主干路、次干路和支路4类典型场景。基于这一划分开展对比实验,结果如表2所示。从整体结果来看,模型在快速路、主干路、次干路及支路等多种道路结构中均保持稳定且较高的分割精度,整体平均交并比达到95.68%,总体精度为97.36%,表明该方法具备良好的场景泛化能力。进一步对不同道路类型进行对比可以发现,模型在简单和复杂的道路场景均能取得良好的分割效果,如图6所示。具体而言,在快速路场景中(图6场景Ⅰ),该场景中车道宽阔、路侧遮挡相对较少,路侧交通地物与行道树在空间分布上边界清晰,使得BG-MSNet模型在路侧交通地物和行道树类别上的交并比分别达到94.90%和99.41%,显著高于其他道路类型。在主干路和次干路场景中(图6场景Ⅱ和场景Ⅲ),道路空间逐渐收紧,路侧设施种类增多,路侧交通地物、行道树及其他地物之间的交错与粘连现象明显增强,极大地增强了场景的复杂性,但BG-MSNet模型在路侧交通地物的分割交并比仍能达到90%以上的良好效果。该现象表明,边界引导几何编码模块在一定程度上缓解了杆状物与周围植被之间的特征混叠,而多尺度特征融合机制则通过引入高层语义信息,稳定了对路灯、交通标志牌、交通信号灯多类型路侧交通地物的整体判别。支路场景(图6场景Ⅳ)进一步放大了分割任务的难度。道路狭窄、视角变化频繁,加之行道树枝叶与杆状设施高度交织,点云中局部结构往往呈现出强噪声和不完整性。在这种条件下,编码阶段的边界约束能够在早期阻

断误导性特征扩散，同时输入特征增强可以增强路侧交通地物与行道树的可区分度，而解码阶段的多尺度自适应融合则通过整合不同分辨率下的上下文信息，弥补局部观测不足带来的语义不确定性。因此，尽管路侧交通地物的交并比在次干路中下降至 90.14%，BG-MSNet 模型仍能取得 95.05% 的平均交并比和 97.45% 的总体精度，表现出对高密度复杂环境的良好适应性。综上，输入特征增强、边界引导与多尺度语义建模的协同作用，使 BG-MSNet 模型在不同等级道路场景下对多类路侧交通地物的分割结果保持了较高的一致性与稳定性。

表 2　BG-MSNet 在不同道路类型的分割结果

道路类型	交并比/%				平均交并比/%	总体精度/%
	路侧交通地物	行道树	路面	其他		
快速路	94.90	99.41	97.83	93.63	96.45	97.62
主干路	93.36	98.31	97.38	96.36	96.35	97.45
次干路	90.14	98.27	98.04	93.02	92.09	96.90
支路	88.56	98.05	98.91	94.67	95.05	97.45
总体	91.74	98.51	98.04	94.42	95.68	97.36

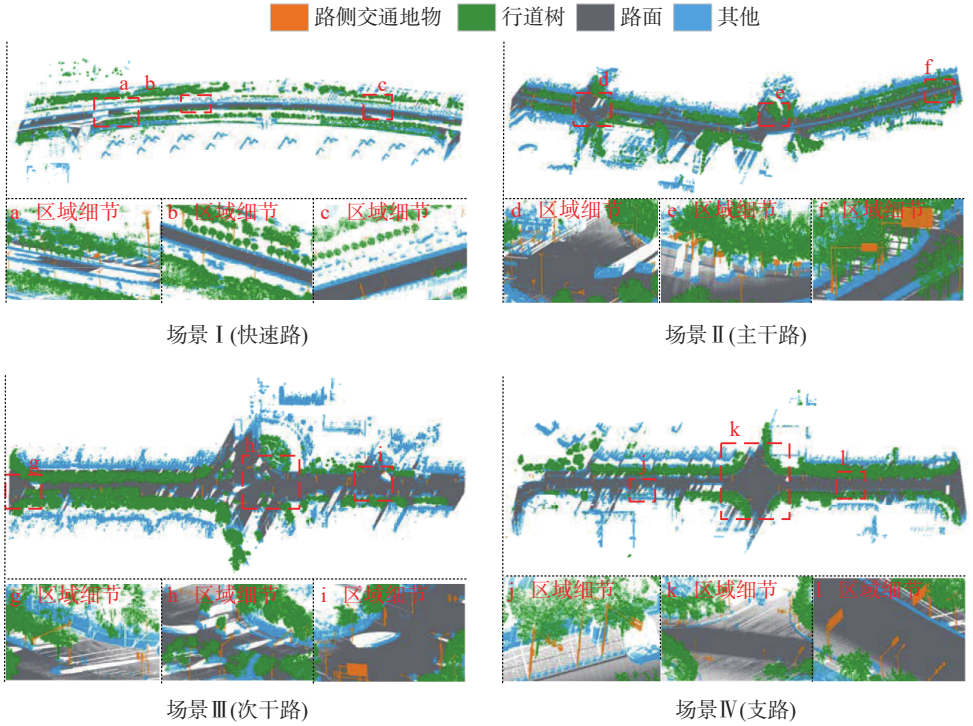


图 6　BG-MSNet 模型在不同道路类型的分割结果

2.4　对比实验与结果分析　为进一步验证 BG-MSNet 模型在感知路侧交通地物任务中的优势，选取 4 个具有代表性的模型（KPConv、RandLANet、SCFNet 和 Point Transformer V3）在金山数据集以及 Toronto3D 和 Paris-Lille-3D 两个公开数据集进行对比分析，为突出模型对路侧交通地物的实际感知能力，对两个公开数据集的原始标签进行统一重映射，将其归并为路侧交通地物、行道树、路面及其他 4 类，对比实验结果如表 3 所示。同时，为了从直观层面揭示不同方法在真实城市场景中的表现差异，进一步选取测试集中具有代表性的典型道路场景进行可视化分析，如图 7 所示。

通过对比不同模型的分割结果可知，BG-MSNet 模型在性能上具有显著优势，3 份数据集的平均交并比达 89.48%。与 KPConv、RandLANet、SCFNet、Point Transforemer V3 相比，平均交并比分别提高了 9.29、1.96、1.64、2.31 百分点。其中，实验数据Ⅰ覆盖快速路、主干路等多种道路形态，场景丰富多样。

BG-MSNet模型在该数据集上的平均交并比达到95.68%,其中路侧交通地物的交并比提升至91.74%,显著高于对比方法,表明该模型在多场景条件下具备较强的泛化能力和稳定性。在路侧交通地物高度密集的城区道路场景中(实验数据Ⅱ和实验数据Ⅲ),BG-MSNet模型在路侧交通地物的交并比和平均交并比仍为最高值,表明其对复杂环境变化具有更强的适应性。综合3组数据的实验结果可以看出,BG-MSNet模型在不同数据来源、不同场景复杂度条件下均能保持稳定输出,验证了该模型在实际城市场景中的有效性与泛化潜力。

表3 数据集对比实验结果

数据集	方法	交并比/%				平均交并比/%
		路侧交通地物	行道树	路面	其他	
实验数据Ⅰ	KPConv	80.10	97.37	98.43	92.47	92.09
	RandLANet	84.06	97.56	98.68	93.26	93.39
	SCFNet	83.69	98.12	98.56	93.03	93.35
	Point Transformer V3	82.46	94.15	**98.72**	91.47	91.70
	BG-MSNet	**91.74**	**98.51**	98.04	**94.42**	**95.68**
实验数据Ⅱ	KPConv	60.97	86.86	86.25	8.50	60.65
	RandLANet	90.01	92.99	93.89	46.30	80.80
	SCFNet	89.78	92.85	94.24	49.16	81.51
	Point Transformer V3	87.81	92.18	**94.30**	47.43	80.43
	BG-MSNet	**90.32**	**93.17**	93.86	**49.36**	**81.68**
实验数据Ⅲ	KPConv	73.04	83.61	95.78	98.89	87.83
	RandLANet	75.98	84.54	94.12	98.89	88.38
	SCFNet	81.39	80.41	94.26	98.57	88.66
	Point Transformer V3	81.56	83.70	93.29	**98.93**	89.37
	BG-MSNet	**81.67**	**87.70**	**96.04**	98.92	**91.08**
总体情况	KPConv	71.37	89.28	93.49	66.62	80.19
	RandLANet	83.35	91.70	95.56	79.48	87.52
	SCFNet	84.95	90.46	95.69	80.25	87.84
	Point Transformer V3	83.94	90.01	95.44	79.28	87.17
	BG-MSNet	**87.91**	**93.13**	**95.98**	**80.90**	**89.48**

注:表中加黑数据为最优解,下同。

通过对比可视化结果可以发现,在简单道路场景(图7场景A和B)中,路侧交通地物形态完整、遮挡较少,点云结构清晰,多数对比方法均能给出较为完整的目标轮廓。然而,在复杂场景(图7场景C、D、E和F)中,路侧交通地物与行道树高度交织,路侧交通地物类型多样,且点云存在明显遮挡、缺失和噪声干扰。此时,依赖局部几何一致性的KPConv易受到邻域内异类点干扰,导致杆状物边界模糊;RandLA-Net虽然在效率上具有优势,但其随机采样策略在高密度混合区域中容易削弱对关键结构的持续关注;SCFNet在多尺度上下文建模方面表现稳定,却在复杂边界处仍存在跨类别特征扩散的问题;Point Transformer V3的全局建模能力在复杂场景下虽能保持整体一致性,但对局部细长结构的精细刻画仍显不足。这些问题使得模型在路侧交通地物感知结果中表现为分割的路侧交通地物断裂,与树干或附属设施粘连,甚至局部漏检。相比之下,BG-MSNet模型在复杂场景中的优势更加突出。一方面,边界引导几何编码模块在编码早期对特征传播路径施加约束,有效抑制了路侧交通地物与行道树之间的特征混叠,使模型在高遮挡区域仍能维持清晰的目标轮廓;另一方面,多尺度特征自适应融合模块在解码阶段动态整合不同分辨率的语义与几何信息,使得即便在局部观测不完整的情况下,模型依然能够借助高层语义

上下文补偿细节缺失。

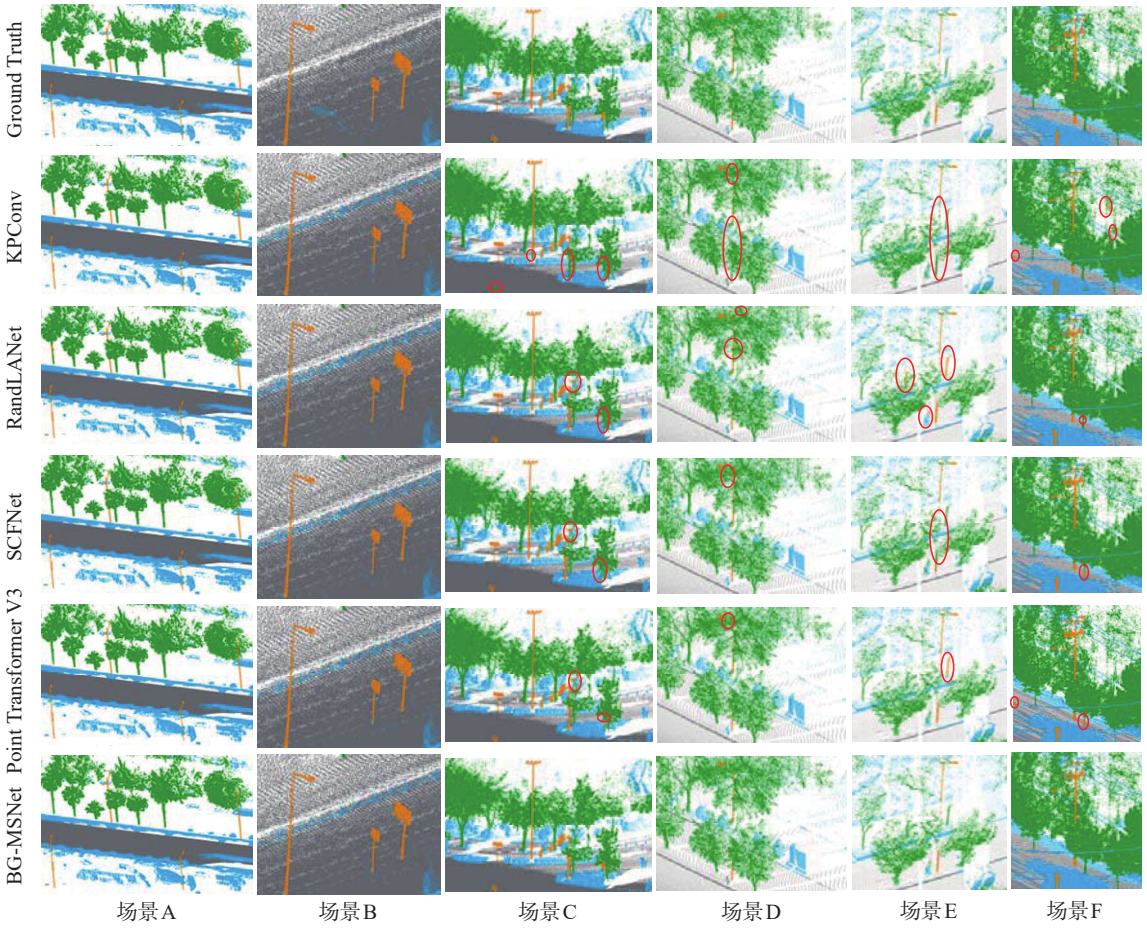


图 7　数据集在典型场景中路侧交通地物感知结果对比

表 4 给出了不同模型在性能方面的对比结果。其中，模型参数量用于表征模型的规模与复杂度，推理时间则表示在 Toronto-3D 数据集上完成网络测试所需的总时间。由表 4 可以看出，BG-MSNet 模型的参数量显著低于 KPConv、SCFNet 和 Point Transformer V3，仅略高于 RandLA-Net。在保持相对紧凑模型规模的前提下，该模型取得了最优的分割精度。在推理效率方面，BG-MSNet 模型的推理时间与以高效率著称的 RandLA-Net 相比略有增加，但整体仍处于可接受范围。综合模型精度、参数规模与计算效率等因素，可以认为 BG-MSNet 在分割性能与计算开销之间实现了较为合理的权衡，体现出良好的综合性能。

表 4　模型性能对比结果

方法	参数量/MiB	推理时间/s	平均交并比/%
KPConv	14.81	366.92	80.19
RandLANet	**5.17**	**247.81**	87.52
SCFNet	12.84	262.95	87.84
Point Transformer V3	12.25	304.68	87.17
BG-MSNet	6.38	289.24	**89.48**

综上分析，本方法能在复杂城市场景中有效抑制特征混叠，保持目标结构完整性，在多数据集、多场景条件下均表现出稳定且突出的路侧交通地物感知能力，同时有效平衡网络计算效率，具有较高的应用价值。

2.5　消融实验与特征可视化分析　为进一步探究网络的关键模块和架构设计的有效性，在金山数据集上

构建不同网络模块组合进行多次消融实验。其中,Model-I为仅使用MLP作为特征提取器的基准网络,Model-Ⅱ集成了边界引导模块,Model-Ⅲ进一步集成了输入特征增强模块,Model-Ⅳ为本文所构建的完整模型。各消融模型在测试数据集上对路侧交通地物感知性能如表5所示,不同消融网络对路侧交通地物注意力可视化结果如图8所示。

表5 不同网络模块和结构设计对路侧交通地物感知性能

方法	FA	BGEM	MFAF	路侧交通地物
				交并比/%
Model-I				84.30
Model-Ⅱ		P		87.36
Model-Ⅲ	P	P		88.24
Model-Ⅳ	P	P	P	**91.74**

注:FA为特征增强模块,BGEM为边界引导几何编码模块,MFAF为多尺度特征自适应融合模块,P表示测试网络集成了该模块。

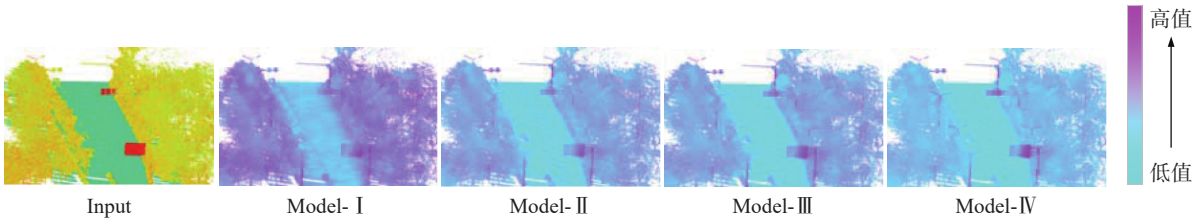


图8 不同消融网络对路侧交通地物注意力可视化结果

结果表明,逐步引入本文所构建的模块后,路侧交通地物的交并比从84.30%提升到91.74%。其中,基准模型Model-I对局部点特征的建模主要依赖几何邻域内的简单聚合机制。在缺乏显式边界约束与多源先验信息的情况下,模型在路侧交通地物上的交并比仅为84.30%。从注意力可视化结果可以观察到,该模型对路侧交通地物的响应分布较为分散,尤其在与行道树或其他附属设施相互贴近的区域,特征激活容易被周围高密度点云干扰,反映出其对细长结构和复杂边界的辨识能力存在明显不足。在引入边界引导几何编码模块后,路侧交通地物的交并比提升至87.36%。体现了边界信息在编码早期对特征传播路径的有效约束作用。通过抑制边界点在局部聚合过程中的贡献,模型能够在一定程度上阻断跨类别特征的无约束扩散,使路侧交通地物区域逐渐形成更加集中的注意力响应。这一现象在树木与交通设施交错分布的场景中尤为明显,说明边界引导机制对缓解几何相似目标之间的特征混叠具有实际价值。进一步融合输入特征增强模块后,交并比继续提升至88.24%。可见光波段植被指数与点云粗糙度等先验特征的引入,使模型在特征空间中获得更具判别力的初始表示,有助于区分自然地物与人工地物。当多尺度特征自适应融合模块进一步引入,形成完整模型时,路侧交通地物的交并比达到91.74%,性能提升最为显著。多尺度融合机制通过在解码阶段动态整合不同分辨率下的语义与几何信息,使模型既能保留低层细节线索,又能借助高层语义约束稳定整体判别结果。注意力可视化结果表明,此时模型提取的目标结构特征则更加平滑,细节更加丰富。综上所述,BG-MSNet模型通过输入特征增强、边界引导几何编码与多尺度特征融合在不同阶段协同作用,提升了对路侧交通地物的感知能力。

3 结 论

本文针对复杂城市场景中路侧交通地物因形态多样、边界模糊且易受遮挡而难以稳定感知的问题,提出了一种融合边界引导与多尺度特征协同建模的路侧交通地物感知框架—BG-MSNet。

(1)BG-MSNet模型利用边界引导几何编码模块,能够在预测边界信息的引导下,准确编码局部特征的几何信息,并防止信息跨越边界传播,从而有效解决交错粘连地物的分割问题。

(2)BG-MSNet模型利用多尺度特征自适应融合模块,自适应地融合低分辨率的深层特征与高分辨

率的浅层特征，捕捉不同形状和尺寸的路侧交通地物的细节与上下文信息，从而提高了网络对不同尺度地物的感知能力。

（3）实验结果表明，BG-MSNet 模型在金山、Toronto3D 以及 Paris-Lille-3D 3 份具有不同数据来源与场景特征的数据集上的平均交并比与路侧交通地物交并比分别达到 89.48% 和 87.91%，在快速路、主干路、次干路和支路 4 种道路场景中的路侧交通地物交并比分别为 94.90%、93.36%、90.14% 和 88.56%，表明该模型在多场景条件下均表现出稳定的性能优势，且相较于其他模型，展现了更强的鲁棒性和优越的分割效果。

参考文献：

[1] 杨必胜，陈驰，董震. 面向智能化测绘的城市地物三维提取 [J]. 测绘学报，2022，51(7)：1476−1484.
Yang B S, Chen C, Dong Z. 3D geospatial information extraction of urban objects for smart surveying and mapping[J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(7): 1476−1484.

[2] 郭仁忠，陈业滨，赵志刚，等. GIS 的科学概念转化：从 Map-based GIS 到 Space-oriented GIS[J]. 测绘学报，2024，53(10)：1853−1862.
Guo R Z, Chen Y B, Zhao Z G, et al. The transformation of the scientific concept of GIS: from Map-based GIS to Space-oriented GIS[J]. Acta Geodaetica et Cartographica Sinica, 2024, 53(10): 1853−1862.

[3] Riveiro B, González-jorge H, Martínez-sánchez J, et al. Automatic detection of zebra crossings from mobile LiDAR data[J]. Optics & Laser Technology, 2015, 70: 63−70.

[4] 刘华. 车载激光点云地物提取与分类研究 [J]. 测绘学报，2020，49(11)：1506.
Liu H. Object points extraction and classification of mobile LiDAR point clouds[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(11): 1506.

[5] 米晓新，杨必胜，董震. 车载激光点云道路场景可视域快速计算与应用 [J]. 武汉大学学报(信息科学版)，2020，45(2)：258−264,
Mi X X, Yang B S, Dong Z. Fast visibility analysis and application in road environment with mobile laser scanning data[J]. Geomatics and Information Science of Wuhan University, 2020, 45(2): 258−264,

[6] 杨必胜，董震. 点云智能研究进展与趋势 [J]. 测绘学报，2019，48(12)：1575−1585.
Yang B S, Dong Z. Progress and perspective of point cloud intelligence[J]. Acta Geodaetica et Cartographica Sinica, 2019, 48(12): 1575−1585.

[7] Xu Y S, Sun Z H, Hoegner L, et al. Instance segmentation of trees in urban areas from MLS point clouds using supervoxel contexts and graph-based optimization[C]//Proceedings of the 2018 10th IAPR Workshop on Pattern Recognition in Remote Sensing. Beijing: IEEE, 2018: 1–5.

[8] 董震，杨必胜. 车载激光扫描数据中多类目标的层次化提取方法 [J]. 测绘学报，2015，44(9)：980−987.
Dong Z, Yang B S. Hierarchical extraction of multiple objects from mobile laser scanning data[J]. Acta Geodaetica et Cartographica Sinica, 2015, 44(9): 980−987.

[9] Xu M B, Zhong X T, Zhong R F. A method for automatic extraction and individual segmentation of urban street trees from laser point clouds[J]. Optics & Laser Technology, 2025, 180: 111431.

[10] Fan W, Chenglu W, Jonathan L. Automated extraction of urban trees from mobile LiDAR point clouds[C]//Proceedings of SPIE 9901, 2nd ISPRS International Conference on Computer Vision in Remote Sensing. Xiamen: SPIE, 2016 : 159−164.

[11] 王鹏，刘如飞，马新江. 车载激光点云中杆状目标自动提取 [J]. 遥感信息，2017，32(5)：52−56.
Wang P, Liu R F, Ma X J. Automatic extraction of pole-like objects from vehicle borne laser scanning point clouds[J]. Remote Sensing Information, 2017, 32(5): 52−56.

[12] Yang B S, Dong Z, Liu Y, et al. Computing multiple aggregation levels and contextual features for road facilities recognition using mobile laser scanning data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 126: 180−194.

[13] Lehtomäki M, Jaakkola A, Hyyppä J, et al. Object classification and recognition from mobile laser scanning point clouds in a

road environment[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(2): 1226−1239.

[14] 李永强, 李鹏鹏, 董亚涵, 等. 车载 LiDAR 点云数据中杆状地物自动提取与分类 [J]. 测绘学报, 2020, 49(6): 724−735. Li Y Q, Li P P, Dong Y H, et al. Automatic extraction and classification of pole-like objects from vehicle LiDAR point cloud[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(6): 724−735.

[15] Yu Y T, Li J, Yu J, et al. Pairwise three-dimensional shape context for partial object matching and retrieval on mobile laser scanning data[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(5): 1019−1023.

[16] Qi C R, Su H, Mo K, et al. Pointnet: deep learning on point sets for 3d classification and segmentation[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 77−85.

[17] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds[J]. ACM Transactions on Graphics (TOG), 2019, 38(5): 146.

[18] Thomas H, Qi C R, Deschaud J E, et al. KPconv: flexible and deformable convolution for point clouds[C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 6410−6419.

[19] Hu Q Y, Yang B, Xie L H, et al. RandLA-Net: efficient semantic segmentation of large-scale point clouds[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11105−11114.

[20] Fan S Q, Dong Q L, Zhu F H, et al. SCF-Net: learning spatial contextual features for large-scale point cloud segmentation[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 14499−14508.

[21] Wu X Y, Jiang L, Wang P S, et al. Point transformer v3: simpler, faster, stronger[C]//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024: 4840−4851.

[22] 汪小钦, 王苗苗, 王绍强, 等. 基于可见光波段无人机遥感的植被信息提取 [J]. 农业工程学报, 2015, 31(5): 152−159. Wang X Q, Wang M M, Wang S Q, et al. Extraction of vegetation information from visible unmanned aerial vehicle images[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(5): 152−159.

[23] Chen J Y, Fang Q, Zhang D L, et al. A critical review of automated extraction of rock mass parameters using 3D point cloud data[J]. Intelligent Transportation Infrastructure, 2023, 2: liad005.

[24] Gong J Y, Xu J C, Tan X, et al. Boundary-aware geometric encoding for semantic segmentation of point clouds[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [S. l.]: AAAI, 2021 : 11423−11432.

[25] Koonce B. ResNet 50[M]//KOONCE B. Convolutional neural networks with swift for tensorflow: image recognition and dataset categorization. Berkeley : Apress, 2021: 63−72.

[26] Mao A Q, Mohri M, Zhong Y T. Cross-entropy loss functions: theoretical analysis and applications[C]//Proceedings of the 40th International Conference on Machine Learning. Hawaii: PMLR, 2023: 23803−23828.

[27] Cui Y, Jia M L, Lin T Y, et al. Class-balanced loss based on effective number of samples[C]//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 9260−9269.

[28] Tang L Y, Zhan Y B, Chen Z, et al. Contrastive boundary learning for point cloud segmentation[C]//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 8479−8489.

[29] Tan W K, Qin N N, Ma L F, et al. Toronto-3D: a large-scale mobile LiDAR dataset for semantic segmentation of urban roadways[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2020: 797−806.

[30] Roynard X, Deschaud J E, Goulette F. Paris-Lille-3D: a large and high-quality ground-truth urban point cloud dataset for automatic segmentation and classification[J]. The International Journal of Robotics Research, 2018, 37(6): 545−557.

[31] Shuai H, Xu X, Liu Q S, et al. Backward attentive fusing network with local aggregation classifier for 3D point cloud semantic segmentation[J]. IEEE Transactions on Image Processing, 2021, 30: 4973−4984.

作者贡献声明

赖启印负责论文的构思与设计，数据收集与分析处理，论文的撰写。方莉娜提供论文经费与资源支持，指导与监督，负责论文的修改。

利益冲突声明

不存在已知的可能影响本论文所报告工作的竞争性经济利益或个人关系。

伦理声明

本文不涉及人类或动物的生物学研究。

电子补充材料

补充材料可在本文的在线版本中获取 https://doi.org/10.65658/j.hndk.2026022801。

数据可用性

实验数据Ⅱ与实验数据Ⅲ为公开数据集，如需获取与本文相关的其他数据，可向通信作者提出申请。

AI 使用声明

本文在完成初稿后使用 AI 对文字内容进行了润色，并在此基础上进行了修改。

致谢/Acknowledgements

本文得到国家自然科学基金项目（42071446）的支持。

This work was supported by the National Natural Science Foundation of China (42071446).

作者简介

赖启印（2001—），男，福建泉州人，福州大学 2023 级地理学专业硕士研究生。E-mail: Rain57@163.com。

方莉娜（1983—），女，广西桂林人，副研究员，博士，研究方向：激光雷达数据处理与三维重建。E-mail: fangln@fzu.edu.cn。

（责任编辑：张秀梅，英文校对：吴　慰）

This is an open access article under the terms of the Creative Commons Attribution 4.0 International License (CC BY 4.0, https://creativecommons.org/licenses/by/4.0/).

© The Author(s) 2026. Published by Journal Editorial Department of Hainan University.