

# 基于结构频谱感知框架的配电网点云语义分割

唐友源<sup>1,2</sup> 张辉<sup>2,3</sup> 杜瑞<sup>2,3</sup> 张恺宁<sup>2,3</sup> 曹云康<sup>2,3</sup>  
别克扎提·巴合提<sup>2,3</sup> 陈厚权<sup>2,3</sup> 王耀南<sup>2,3</sup>

**摘要** 配电网点云语义分割对于实现无人化巡检与智能电网运维具有重要意义。尽管已有方法在空间建模与结构增强方面取得一定进展,但在频谱特征挖掘与大规模点云处理效率上仍面临突出挑战。为此,提出一种结构频谱感知框架(SSAF),以提升长距离配网场景下的点云表达能力。在数据预处理阶段,提出一种结合结构引导的层级滤波策略与结构感知的样本划分方法,在压缩冗余背景点云的同时,有效保持电力杆塔、电力线等关键目标的结构完整性与连续性。在语义分割阶段,构建空谱协同语义分割网络,引入局部极坐标系以增强模型对方向特征的建模能力,并设计基于注意力图的动态融合机制,实现空间特征与频谱特征之间的自适应交互与信息增强。实验结果表明,SSAF能在真实配电网场景点云数据集上实现更高的分割精度与推理效率,在多个关键指标上优于现有代表性方法,验证了其在复杂场景下的实用性和工程推广潜力。

**关键词** 配电网点云; 语义分割; 结构频谱感知; 空谱融合; 极坐标频谱变换

**引用格式** 唐友源, 张辉, 杜瑞, 张恺宁, 曹云康, 别克扎提·巴合提, 陈厚权, 王耀南. 基于结构频谱感知框架的配电网点云语义分割. 自动化学报, 2026, 52(4): 833-845

**DOI** 10.16383/j.aas.c250540

**CSTR** 32138.14.j.aas.c250540

## Semantic Segmentation of Distribution Network Point Clouds Based on a Structure Spectrum-Aware Framework

TANG You-Yuan<sup>1,2</sup> ZHANG Hui<sup>2,3</sup> DU Rui<sup>2,3</sup> ZHANG Kai-Ning<sup>2,3</sup> CAO Yun-Kang<sup>2,3</sup>  
BIEKEZATI Baheti<sup>2,3</sup> CHEN Hou-Quan<sup>2,3</sup> WANG Yao-Nan<sup>2,3</sup>

**Abstract** The semantic segmentation of point clouds in power distribution networks is of great significance for enabling unmanned inspection and intelligent grid operation and maintenance. Although existing methods have made some progress in spatial modeling and structural enhancement, they still face prominent challenges in spectral feature extraction and the efficiency of large-scale point cloud processing. To address these issues, this paper proposes a structure spectrum-aware framework (SSAF) to enhance the expressive capability of point clouds in long-distance distribution network scenarios. In the data preprocessing stage, a structure-guided hierarchical filtering strategy and a structure-aware sample partitioning method are designed to reduce redundant background points while preserving the structural integrity and continuity of key objects such as poles and wires. During the semantic segmentation stage, a spatial-spectral collaborative semantic segmentation network is constructed, in which local polar coordinates are introduced to enhance direction-sensitive feature modeling. Furthermore, a dynamic fusion mechanism based on attention maps is employed to enable adaptive interaction and information enhancement between spatial and spectral features. Experimental results show that SSAF achieves higher segmentation accuracy and inference efficiency on real-world distribution network point cloud datasets. It outperforms existing representative methods across multiple key metrics, demonstrating its practicality and engineering generalization potential in complex scenarios.

**Keywords** distribution network point cloud; semantic segmentation; structure spectrum awareness; spatial-spectral fusion; polar spectral transform

**Citation** Tang You-Yuan, Zhang Hui, Du Rui, Zhang Kai-Ning, Cao Yun-Kang, Biekezati Baheti, Chen Hou-Quan, Wang Yao-Nan. Semantic segmentation of distribution network point clouds based on a structure spectrum-aware framework. *Acta Automatica Sinica*, 2026, 52(4): 833-845

收稿日期 2025-10-13 录用日期 2025-12-31

Manuscript received October 13, 2025; accepted December 31, 2025

国家自然科学基金重大项目(62595801), 湖南省十大技术攻关项目(2024GK1010), 湖南省自然科学基金重点项目(2025JJ30024), 国网湖南省电力有限公司科技项目(5216A522001Y, 5216A5240003, 5216A.J250008)资助

Supported by Major Program of National Natural Science Foundation of China (62595801), Ten Technical Research Projects of Hunan Province (2024GK1010), Natural Science Foundation of Hunan Province (2025JJ30024), and Science and Technology Project of State Grid Hunan Electric Power Co., Ltd.

(5216A522001Y, 5216A5240003, 5216A.J250008)

本文责任编辑 樊彬

Recommended by Associate Editor FAN Bin

1. 长沙理工大学人工智能学院 长沙 410114 2. 机器人视觉感知与控制技术国家工程研究中心 长沙 410012 3. 湖南大学人工智能与机器人学院 长沙 410012

1. School of Artificial Intelligence, Changsha University of Science and Technology, Changsha 410114 2. National Engineering Research Center for Robot Visual Perception and Control Technology, Changsha 410012 3. School of Artificial Intelligence and Robotics, Hunan University, Changsha 410012

配电网是电网系统的重要组成部分,其运行安全直接关系到整个电力系统的稳定性与可靠性。随着无人机(unmanned aerial vehicle, UAV)与深度学习技术的快速发展,基于无人机激光雷达(UAV-light detection and ranging, UAV-LiDAR)的智能巡检模式广泛应用于电力系统的状态感知与隐患排查,为实现电网设备的精准诊断与高效维护提供了重要技术支撑<sup>[1-4]</sup>。

从大规模点云数据中准确识别电力杆塔、电力线及其背景环境信息,是实现 UAV-LiDAR 智能化巡检的关键。早期研究主要依赖手工构建的几何特征与启发式规则进行分类与分割。Kim 等<sup>[5]</sup>通过局部几何描述子训练随机森林模型,实现点云的初步自动分类;Lehtomäki 等<sup>[6]</sup>基于随机样本一致性(random sample consensus, RANSAC)<sup>[7]</sup>算法提升对线状结构的提取精度;Shen 等<sup>[8]</sup>则结合多层高程阈值策略,完成电力线区域的点云分离。这些方法具有良好的可解释性与工程实现便捷性,但高度依赖规则设计与先验假设,难以有效适应配电网场景中复杂多样的自然背景与结构变化<sup>[9]</sup>。

随着深度学习在三维点云处理领域的持续突破,端到端的语义分割网络逐渐取代传统手工特征方法,成为研究主流<sup>[10-12]</sup>。PointNet 系列方法<sup>[13-14]</sup>推动点云分割由“局部启发式”向“端到端学习”的转变,并在通用任务中取得显著进展。然而,这类方法过度依赖局部欧氏邻域,仅能捕捉点间的几何邻近性,缺乏对方向连续性与结构约束建模,导致电力杆塔和电力线目标出现语义断裂与边界模糊<sup>[15-17]</sup>。为弥补局部建模不足,后续研究尝试引入图神经网络<sup>[18-20]</sup>和注意力机制<sup>[21-24]</sup>,以建模非局部依赖并提升全局特征表达。但仍局限于空间域建模,对噪声与拓扑扰动敏感,整体性能提升有限。

这一限制促使研究者探索频谱域建模。与依赖局部邻域的空间方法不同,频谱方法通过频率分量刻画几何结构的连续性与变化模式,能够更敏锐地感知不同类别的结构特征。在配电网点云场景中,电力杆塔对应局部高频集中结构,电力线呈现细长方向性模式,植被则表现为更随机的频谱分布。这些差异为频谱方法提供判别信号,使其在捕捉长距离依赖的同时增强对结构类别的区分能力。已有工作在二维任务中验证了频谱建模的有效性<sup>[25]</sup>,但点云的无序性与不规则性使其直接应用仍面临挑战,Wen 等<sup>[26]</sup>通过图小波变换增强局部结构表征,进一步验证了频谱建模在结构刻画中的潜力。但该方法构建的局部谱算子主要作用于图拓扑,计算复杂度较高,且在方向连续性和旋转鲁棒性方面存在不足。进一

步的研究转向空谱融合方法,Rizaldy 等<sup>[27]</sup>提出的双分支 Transformer,通过跨域注意力实现空间与频谱特征交互,在模态互补性上取得进展,但其频谱分支基于规则网格构建,难以有效刻画细长结构的局部方向性特征。综上所述,频谱建模与空谱融合技术为提升点云表征能力提供了可能,然而在配电网复杂场景的实际应用中,仍面临以下三方面关键局限:

1) 现有频谱方法通常依赖图结构构建,将点云转化为图信号后再进行变换。这一过程不仅带来额外的计算复杂度,而且频谱响应对局部结构方向的刻画能力有限,难以稳定表征电力线等细长目标的方向连续性与局部几何差异,导致语义表征不稳定<sup>[26]</sup>。

2) 塔线交汇、植被邻近干扰等复杂区域普遍存在类别混叠,现有空谱联合方法多依赖表层特征耦合,未能显式建模空间与频谱的互补关系,难以保持同类别的语义一致性<sup>[28]</sup>。

3) 配电网场景点云规模往往达到数千万至上亿点,其中大量冗余的背景点以及整体样本尺度直接增加了特征提取和空谱交互的计算量,导致模型推理效率难以满足电网巡检对实时性的工程需求<sup>[15-16]</sup>。

针对上述挑战,本文构建一个结构频谱感知框架(structure spectrum-aware framework, SSAF),通过结合结构引导信息与频谱特征,对冗余点云信息进行有效压缩与筛减,并增强模型的特征提取与语义表征能力。在预处理阶段,设计结构引导的数据滤波与样本划分方法,以电力杆塔与电力线为先导生成语义完整的子样本,在保持关键结构的同时减少数据规模并缓解类别不均衡。在分割阶段,设计空谱协同语义分割网络(spatial-spectral collaborative semantic segmentation network, SSCNet),利用频谱变换提取方向不变的结构特征,并通过双向门控机制实现空间域与频谱域交互式融合,从而在复杂区域保持结构的连续性和边界的一致性。

本文主要贡献总结如下:

1) 提出一种结构频谱感知框架(SSAF),该框架融合结构引导信息与频谱特征,将大规模走廊点云划分为语义完整的子样本,在保留关键结构的同时显著降低单样本点云规模,有效降低计算开销的同时提升点云的语义表征能力。

2) 设计一个空谱协同语义分割网络(SSCNet),在编码阶段并行建模几何与频谱特征,通过基于局部主轴对齐的极坐标建模与一维频谱变换,构建对电力线等细长结构具有旋转不变性的结构谱表征<sup>[29]</sup>,并在网络层面显式融合该结构谱与多尺度空间几何

特征. 实现跨模态特征的深度交互, 从而增强复杂区域的语义一致性与边界判别能力.

3) 构建覆盖 22 条配电线路的大规模 UAV-LiDAR 点云数据集, 并在其上开展系统实验. 实验结果表明, 所提方法在分割精度和推理效率方面均优于现有方法, 验证了其在电网智能巡检中的应用潜力.

## 1 方法原理

### 1.1 框架总览

针对配电网点云场景中关键结构的高效感知与精细化分割需求, 本文提出一种结构频谱感知框架 SSAF. 如图 1 所示, 该框架构建了一个从原始数据获取到高精度语义解析的级联处理流程.

无人机 LiDAR 采集的配电网原始点云通常具有数据规模庞大、背景噪声复杂及类别分布不均衡等固有特点, 直接输入深度学习网络易引发计算效率低下与特征学习困难. 为此, 本研究在数据预处理阶段提出一种结构引导的层级滤波策略与结构感知样本划分方法. 该策略通过层级滤波与结构化样本重组, 在缓解类别不均衡的基础上, 依据电力线与电力杆塔的空间分布先验, 将大范围线路场景划分为多个语义完整的局部子空间, 降低数据规模的同时, 有效避免电力线等细长目标在拓扑结构上的断裂.

在此基础上, 本文进一步提出一种空谱协同语义分割网络 (SSCNet), 旨在实现配电网场景关键类别点云的精准提取. 针对该场景中关键目标存在的显著几何异质性, SSCNet 设计局部极坐标频谱变换模块, 以提取具有旋转不变性的细粒度频谱特

征; 并引入空间-频谱双向门控融合机制, 通过动态交互与自适应加权整合空间与频谱特征, 在保持整体几何拓扑一致性的基础上优化边界区域的判别细节, 最终完成对电力线、电力杆塔及背景的高精度语义分割.

### 1.2 数据预处理与子样本划分

如图 2 所示, 针对大规模配电网点云中存在的背景冗余与噪声干扰问题, 本文提出一套点云预处理流程, 该流程融合结构引导的层级点云滤波与结构感知的样本划分策略, 旨在抑制背景干扰、增强关键目标区域的点云密度与上下文连贯性, 从而为后续语义分割任务提供高质量的结构化输入.

#### 1.2.1 结构引导的层级点云滤波策略

配电网场景中的点云数据存在显著的类别不均衡问题, 其中近地表区域与低矮植被点通常超过总点数的 90%, 导致关键结构类目标在训练中的特征表达受限, 影响模型的判别能力. 现有方法主要采用两类处理策略: 一类是对完整点云直接进行语义分割<sup>[15-16, 18]</sup>; 另一类则基于通用地面滤波算法对数据进行预处理<sup>[17, 21]</sup>. 前者在面对大规模点云数据时计算开销较高, 难以满足高效分割需求; 后者尽管具备一定的地面点剔除能力, 但由于缺乏对场景结构的识别机制, 常将高大非地面背景与关键目标一并保留, 导致网络训练阶段面临明显的类别分布偏移问题.

为应对上述挑战, 本研究提出一种结构引导的层级点云滤波策略. 如图 2(a) 所示, 该策略以几何统计特征为基础, 并引入空间拓扑连续性约束, 在

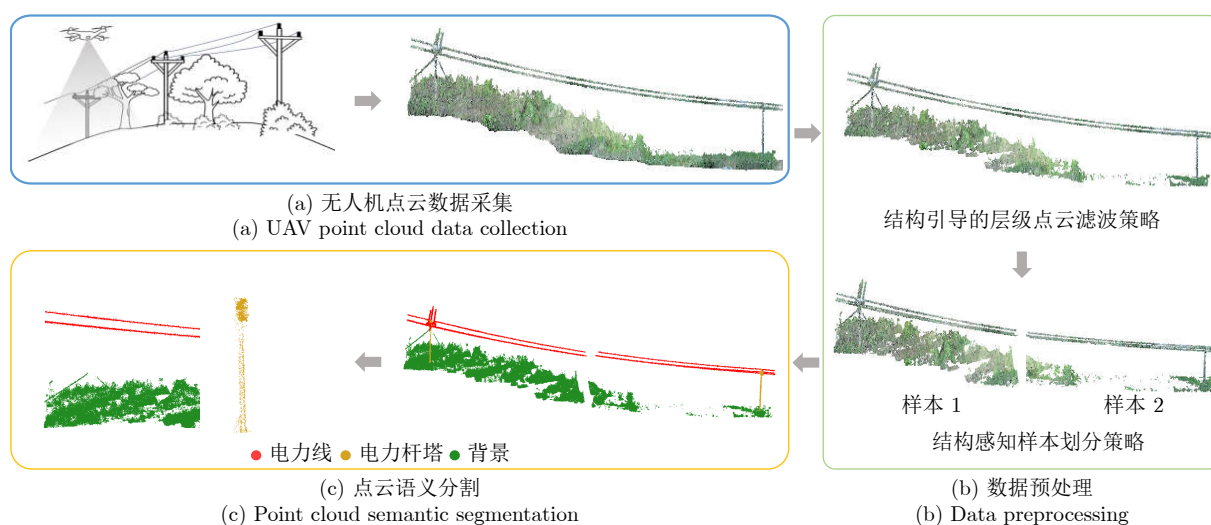


图 1 结构频谱感知框架

Fig.1 The structure spectrum-aware framework




图 2 数据预处理

Fig.2 Data preprocessing

保留关键结构信息的基础上, 滤除大规模的非关键类别点云. 该策略整体过程如下:

首先, 将输入点云按走廊方向投影至  $XOY$  平面; 随后, 采用边长为  $S_g$  的规则网格对点云进行离散化处理, 其中  $S_g$  为网格分辨率参数. 实验结果表明, 将  $S_g$  设定为 1 m 可在处理精度与计算效率之间取得最优平衡. 针对每个网格单元  $g$ , 计算其高程极差  $\Delta z_g = z_{\max}(g) - z_{\min}(g)$  以及高程层的点密度频率变异系数  $\rho_g$

$$\rho_g = \sum_{k=1}^{K-1} |\pi_{g, k+1} - \pi_{g, k}| \quad (1)$$

$$\pi_{g, k} = \frac{n_{g, k}}{\sum_{j=1}^K n_{g, j} + \varepsilon} \quad (2)$$

其中,  $\pi_{g, k}$  表示网格  $g$  在第  $k$  层高度上的相对点密度,  $n_{g, k}$  为该层中的点数,  $\varepsilon$  是一个防止分母为零的极小常数. 随后设定高程极差阈值  $\delta_h = 1.5$  m 及频率变异阈值  $\tau = \text{Quantile}_{0.9}(\{\rho_g\})$ , 其中  $\text{Quantile}_{0.9}(\{\rho_g\})$  表示将所有网格频率变异系数按升序排列后所得的 90% 分位数, 筛选出满足  $\Delta z_g > \delta_h$  或  $\rho_g > \tau$  条件的高变异网格作为候选区域.

针对候选区域内的点云, 进一步采用布料模拟滤波<sup>[30]</sup>进行细粒度的地面点剔除处理, 以提升基础分割精度. 在此基础上, 结合空间拓扑连续性对保留结构进行图建模优化. 具体而言, 首先以高  $\rho_g$  值区域中的电力线候选点作为锚点, 在其半径  $r = 2S_g$  的邻域内构建局部图结构, 通过连通性分析剔除与电力线网络无结构连接的孤立高点, 实现塔线

结构的完整保留与非关键点云的有效抑制.

### 1.2.2 结构感知的样本划分策略

配电网线路点云通常具有数据量庞大和结构跨度较长的特点, 直接将整段线路输入深度学习模型, 易导致计算资源消耗过高及内存占用超限, 影响模型的训练与推理效率. 为控制数据规模, 常用的划分策略包括滑动窗口裁剪与随机采样. 然而, 这些方法缺乏结构连续性约束, 容易造成电力线与电力杆塔等关键目标的断裂, 难以保持局部拓扑关系的完整性, 进而削弱模型对关键部件的语义表示与识别能力.

针对上述问题, 本文提出一种结构感知样本划分策略. 如图 2(b) 所示, 该方法以电力杆塔作为线路网络中的关键支撑节点, 利用其在空间分布中天然的上下文聚合特性, 引导样本划分过程. 通过以电力杆塔为中心构建样本区域, 有效覆盖电力线、电力杆塔等关键类别, 保持局部区域的语义连贯性与结构完整性.

具体实现流程分为两个阶段. 首先, 依据点云的高程极差  $\Delta z$  与频率变异系数  $\rho$  识别电力杆塔候选区域, 其中, 高程极差阈值  $\delta_h$  与频率变异阈值  $\tau$  由电力杆塔高度及点云密度的统计分布结合预备实验确定. 随后, 结合电力杆塔网格与电力线网格的空间分布, 确定电力线的主方向, 以每个候选电力杆塔网格为中心, 选取其邻近的电力线网格作为种子点, 沿该方向执行区域生长操作, 在满足方向一致性与距离连续性的条件下逐步扩展, 直至所有结构候选网格均被分配完成, 自适应生成一组以电力杆塔为中心的结构连续、类别均衡的子样本区域. 该策略通过显式的结构引导方式组织点云数据, 在有效压缩数据规模的同时, 保持关键目标之间的空间连接关系, 为后续语义分割任务提供结构完整的输入样本. 其整体流程如算法 1 所示.

#### 算法 1. 结构感知的样本划分策略

输入. 原始点云  $\mathcal{P} = \{p_i \mid i = 1, 2, \dots, N\}$ .

输出. 结构子样本集合  $\{(\mathcal{X}_k, \mathcal{Y}_k)\}_{k=1}^K$ .

1. 将点云  $\mathcal{P}$  投影至  $XOY$  平面并划分为二维网格单元;
2. 对每个网格计算高程极差  $\Delta z$  与频率变异系数  $\rho$ ;
3. 若  $\Delta z > \delta_h$  或  $\rho > \tau$ , 则标记为结构候选网格;
4. 以候选电力杆塔网格为中心, 沿电力线方向执行区域生长, 结合空间连续性与方向一致性生成结构连续区域  $\mathcal{R}_k$ ;
5. 从每个  $\mathcal{R}_k$  中提取点集及对应标签  $(\mathcal{X}_k, \mathcal{Y}_k)$ , 并适度引入邻域背景点以保留上下文信息;
6. 输出所有结构子样本集合  $\{(\mathcal{X}_k, \mathcal{Y}_k)\}_{k=1}^K$ .

### 1.3 空谱协同语义分割

如图 3 所示, 经 UAV-LiDAR 采集与预处理后的点云由本文提出的空谱协同语义分割网络 SSC-Net 进行处理. 该网络由点云编码器、语义解码器和嵌入于编码路径中的空谱协同感知块 (spectral-spatial collaborative perception block, SSCP-Block) 三部分组成, 旨在实现复杂场景下空间与频谱信息的联合建模与深度融合.

编码阶段首先采用网格采样与  $k$  近邻搜索构建局部邻域, 提取点云的空间关系与局部结构特征. 每个编码层中嵌入一个 SSCP-Block, 包含空间与频谱两个子分支. 空间分支使用局部空间编码捕捉几何特征; 频谱分支则基于局部极坐标频谱变换 (polar regional spectral transform, PRST), 执行环域序列化与圆形快速傅里叶变换, 提取结构边缘处的频率响应特征. 为实现空谱特征的协同建模, 网络引入门控双向交叉融合模块 (bidirectional gated fusion, BGF), 采用交叉注意力机制完成跨域信息交互, 并基于通道级门控权重实现自适应特征融合. 多层编码操作逐步提取多尺度的高维语义特征, 构建从几何描述到语义表达的分层特征表示, 增强网络的表达能力与结构感知能力.

解码阶段将高层语义特征逐层恢复至点云的原始分辨率. 该部分采用最近邻插值进行上采样, 并将上采样结果与编码器中多尺度特征进行融合, 整合局部与全局上下文信息, 增强语义连续性. 融合后的特征输入多层感知机 (multi-layer perceptron, MLP), 完成通道交互与特征增强. 最后, 输出端通过 MLP 语义分割头完成逐点分类, 生成语义标签, 实现点云的端到端语义分割.

#### 1.3.1 局部极坐标频谱变换

针对点云局部邻域中因点排列不确定性所引发的频谱特征表示不稳定问题, 本文提出一种局部极坐标频谱变换 (PRST) 模块. 该模块首先将局部邻域内的无序点云映射至一维角向网格, 继而通过频谱变换与可学习调制, 生成具有强判别性与鲁棒性的频谱表征.

设第  $i$  个中心点的邻域为  $\mathcal{N}(i)$ , 采用  $k$  近邻方式构建 ( $k = 32$ ). 邻域内每个点  $j$  的特征表示为

$$\mathbf{f}_{ij} = [\mathbf{f}_j; (\mathbf{p}_j - \mathbf{p}_i)] \in \mathbf{R}^{C_g} \quad (3)$$

其中,  $\mathbf{f}_j$  表示点  $j$  的输入特征,  $\mathbf{p}_j - \mathbf{p}_i$  为相对坐标差,  $[\cdot; \cdot]$  表示沿通道维的特征拼接操作,  $C_g$  为拼接后的通道维数.

为获得局部邻域内具有方向一致性的角向描述, 本文在每个中心点邻域  $\mathcal{N}(i)$  内基于主成分分析 (principal component analysis, PCA) 构建局部正交基  $\mathbf{e}_1, \mathbf{e}_2, \mathbf{e}_3$ , 其中,  $\mathbf{e}_3$  为估计法向量,  $\mathbf{e}_1, \mathbf{e}_2$  构成切平面. 为消除角度偏移引起的序列不一致性, 将  $\mathbf{e}_1$  与最大主轴对齐, 并设定极角零点沿其正方向, 作为角向编码的参考. 任意邻域点  $j$  关于中心点  $i$  的相对位移为  $\Delta\mathbf{p}_{ij} = \mathbf{p}_j - \mathbf{p}_i$ , 其在切平面上的极角定义为

$$\theta_{ij} = \text{atan2}(\Delta\mathbf{p}_{ij} \cdot \mathbf{e}_2, \Delta\mathbf{p}_{ij} \cdot \mathbf{e}_1) \quad (4)$$

其中,  $\text{atan2}$  表示双参数反正切函数, 用于根据向量在局部基底 ( $\mathbf{e}_1, \mathbf{e}_2$ ) 上的投影值计算其极角方向. 由于不同中心点的邻域规模存在差异, 直接基于邻域点集构造序列会导致特征序列长度不一致, 不利于后续统一建模. 为此, PRST 在已构建的局部极坐

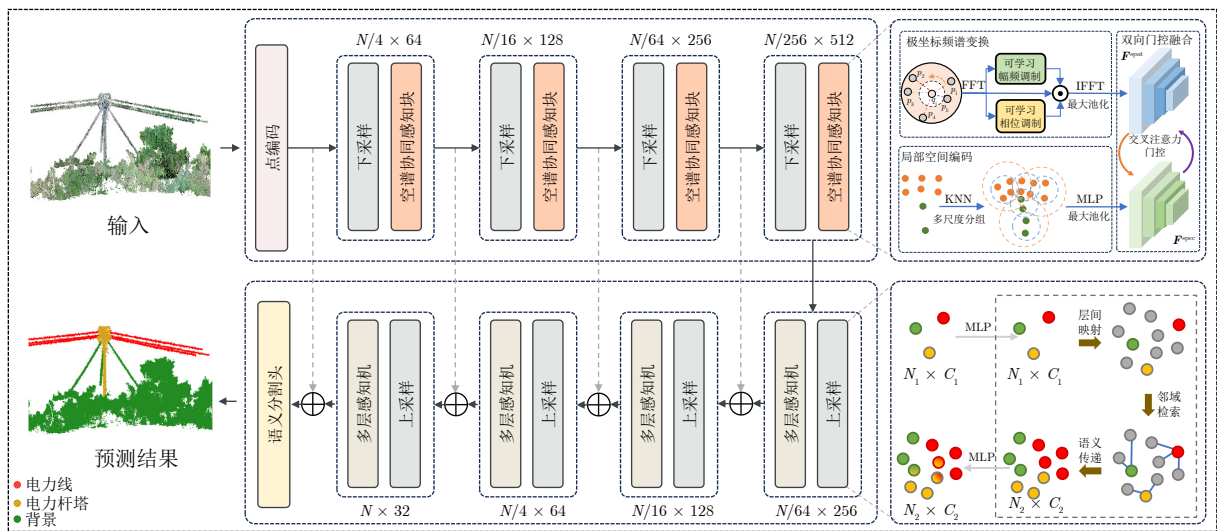


图 3 空谱协同语义分割网络

Fig. 3 Spectral-spatial collaborative semantic segmentation network

标系上引入基于固定角向采样的环形重采样策略. 具体而言, 在区间  $[0, 2\pi)$  上预定义  $S$  个等弧度角度位置  $\mu_s = \frac{2\pi s}{S}$  ( $S = 32$ ), 并在每个采样位置处利用角向核插值, 将邻域内所有点的特征按角差加权聚合至对应的重采样点. 邻域点集被统一映射为长度固定的环形特征序列  $\mathbf{x}_i \in \mathbf{R}^{S \times C_g}$ , 其中每个序列元素对应一个稳定的角向聚合单元. 相应的核插值形式为

$$\mathbf{x}_i[s] = \frac{\sum_{j \in \mathcal{N}(i)} w_{ij}^{(s)} f_{ij}}{\sum_{j \in \mathcal{N}(i)} w_{ij}^{(s)} + \varepsilon}, s = 0, \dots, S-1 \quad (5)$$

其中, 权重  $w_{ij}^{(s)} = \kappa(\text{wrap}(\theta_{ij} - \mu_s))$ , 核函数定义为  $\kappa(\Delta\theta) = \exp(-\frac{\Delta\theta^2}{2\sigma_\theta^2})$ ,  $\sigma_\theta = 0.1 \text{ rad}$ ,  $\varepsilon = 10^{-6}$  用于防止除零,  $\text{wrap}(\cdot)$  表示将角差归一至  $(-\pi, \pi]$ .

对序列执行快速傅里叶变换 (fast Fourier transform, FFT), 仅保留幅度谱用于旋转不变性建模, 并通过可学习频带权重  $\mathbf{W}_{\text{amp}} \in \mathbf{R}^{S \times C_g}$  进行加权, 即

$$\tilde{\mathbf{Y}}_i = |\text{FFT}(\mathbf{x}_i)| \odot \mathbf{W}_{\text{amp}} \quad (6)$$

$$\mathbf{z}_i = \text{Pool}_S(\text{IFFT}(\tilde{\mathbf{Y}}_i)) \in \mathbf{R}^{C_g} \quad (7)$$

其中,  $\odot$  表示逐元素乘法,  $\text{FFT}(\cdot)$  表示快速傅里叶变换,  $\text{IFFT}(\cdot)$  表示逆快速傅里叶变换,  $\text{Pool}_S(\cdot)$  为序列维度的平均池化操作. 相较于直接使用相位信息, 本文采用纯幅度谱建模以提升稳定性.

### 1.3.2 双向门控融合

在配电网点云中, 空间和频谱特征源自不同的特征提取机制, 分别聚焦于局部几何结构和全局方向性特征响应. 这种特征异构性导致其语义偏置不一致: 空间分支在保持结构连续性方面表现稳定, 但在复杂边界处常发生响应扩散; 频谱分支具备敏

感的边界感知能力, 但缺乏对局部拓扑关系的鲁棒建模. 缺乏模态关系约束的特征融合方式将引入模态冲突与响应不一致问题, 特别是在塔线等结构混合区域, 极易导致语义信息割裂.

为此, 本文设计双向门控融合模块 BGF, 旨在实现空间与频谱特征之间的结构感知融合. 如图 4 所示, 该模块以互引导的交叉注意力为核心机制, 建立双模态间的依赖建模通道, 并引入依赖注意力图的通道门控策略, 使融合结果具备针对不同区域的模态偏置调节能力, 从而实现对语义连续性与边界精度的平衡控制.

具体而言, 设空间与频谱特征分别为  $\mathbf{F}^{\text{spat}}$ ,  $\mathbf{F}^{\text{spec}} \in \mathbf{R}^{N \times d}$ ,  $d$  表示输入特征的通道维度. 以空间  $\rightarrow$  频谱方向为例, 首先构造交叉注意力中的查询、键和值向量, 即

$$\mathbf{Q}_s = \phi_q(\mathbf{F}^{\text{spat}}) \quad (8)$$

$$\mathbf{K}_z = \phi_k(\mathbf{F}^{\text{spec}}) \quad (9)$$

$$\mathbf{V}_z = \phi_v(\mathbf{F}^{\text{spec}}) \quad (10)$$

其中,  $\phi_q(\cdot)$ 、 $\phi_k(\cdot)$  和  $\phi_v(\cdot)$  分别为独立的线性层. 投影后  $\mathbf{Q}_s$ ,  $\mathbf{K}_z$ ,  $\mathbf{V}_z \in \mathbf{R}^{N \times d_k}$ . 其中,  $d_k$  表示交叉注意力中查询、键和值向量的嵌入维度, 用于控制特征投影后的表示空间规模.

交叉注意力通过缩放点积的方式, 引导空间特征对频谱响应区域建立选择性关注, 即

$$\hat{\mathbf{F}}^{\text{spat}} = \text{Softmax}\left(\frac{\mathbf{Q}_s \mathbf{K}_z^T}{\sqrt{d_k}}\right) \mathbf{V}_z \quad (11)$$

同理, 在频谱  $\rightarrow$  空间方向上可对称构造, 得到  $\hat{\mathbf{F}}^{\text{spec}}$ . BGF 模块通过引导式注意力机制建立模态间的非对称依赖关系, 使不同模态间的特征交互由静态融合方式转变为引导式调制, 从机制层面缓解空间与频谱响应之间的特征偏移问题.

在此基础上, BGF 引入基于注意力图的通道门控机制, 将模态依赖强度显式编码为融合权重的调控依据. 以  $\mathbf{A}_{s \rightarrow z}$  表示空间到频谱方向的注意力矩阵, 其通道响应向量可通过沿键维度对该注意力矩阵进行全局平均池化 (global average pooling, GAP) 获得.

$$\tilde{\mathbf{a}}_s = \frac{\text{GAP}(\mathbf{A}_{s \rightarrow z})}{\|\text{GAP}(\mathbf{A}_{s \rightarrow z})\|_1 + \varepsilon} \quad (12)$$

频谱方向  $\tilde{\mathbf{a}}_z$  同理构建. 为进一步捕捉空间-频谱模态间的通道依赖关系, 将注意力权重向量  $\tilde{\mathbf{a}}_s$  与  $\tilde{\mathbf{a}}_z$  进行拼接, 形成联合依赖表示, 通过 MLP 生成通道维度上的融合门控向量  $\mathbf{g} \in [0, 1]^{d_k}$ , 具体形式为

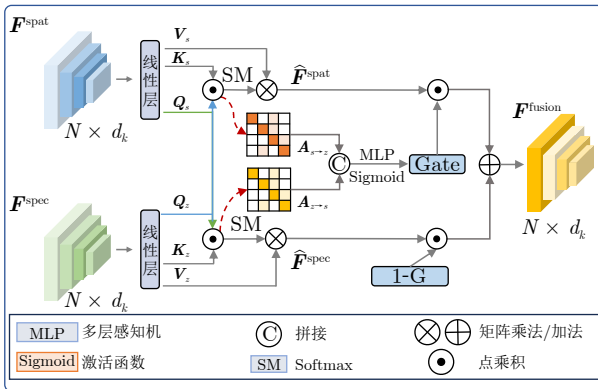


图 4 双向门控融合

Fig. 4 Bidirectional gated fusion

$$\mathbf{g} = \sigma(\text{MLP}([\hat{\mathbf{a}}_s; \hat{\mathbf{a}}_z])) \quad (13)$$

式中,  $\sigma(\cdot)$  表示逐元素的 Sigmoid 激活函数.

最终, 融合结果采用加权方式实现, 即

$$\mathbf{F}^{\text{fusion}} = \mathbf{g} \odot \hat{\mathbf{F}}^{\text{spat}} + (1 - \mathbf{g}) \odot \hat{\mathbf{F}}^{\text{spec}} \quad (14)$$

其中,  $\odot$  表示通道级逐元素乘法. 融合特征  $\mathbf{F}^{\text{fusion}}$  作为该尺度下的统一表征输入后续解码网络, 强化对语义结构的全局一致性建模与细粒度边界刻画能力.

## 2 实验结果与分析

### 2.1 数据采集

本文构建了一个大规模配电网点云数据集, 采用大疆 Matrice 300 RTK 无人机搭载 Zenmuse L1 激光雷达传感器完成采集. 无人机在约 100 m 高度沿配电线路航线飞行, 获取稠密的三维点云数据. 整体采集范围覆盖约 50 km 的线路长度和 5 km<sup>2</sup> 的区域面积, 时间跨度为 2023 年 7 月至 12 月, 包括不同季节和多样化环境条件, 含有电力杆塔 (436 万点)、电力线 (1421 万点)、植被 (4.03 亿点) 等典型目标类别. 图 5 展示了典型走廊场景的点云扫描结果. 数据集按 8 : 2 的比例划分为训练集和测试集, 语义标注由人工完成并经电网专家审核. 本文重点关注电力线、电力杆塔和背景三类目标, 其中地面点视为冗余信息, 已通过结构引导的滤波策略剔除, 不参与后续分割训练.

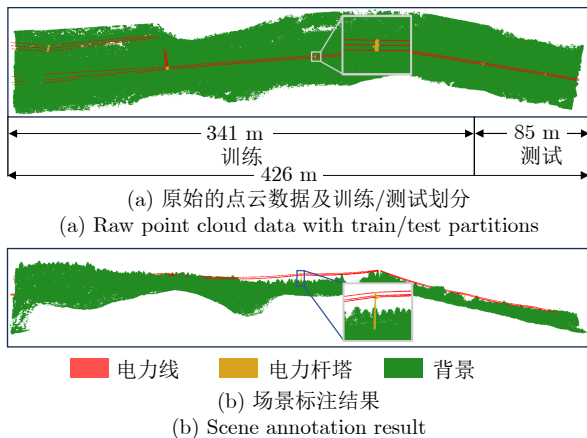


图 5 构建的配电网场景数据集可视化

Fig. 5 Visualization of the constructed distribution network scene dataset

### 2.2 实验设置和评估指标

本文提出的 SSCNet 基于 PyTorch 框架实现,

所有训练与推理实验均在搭载 NVIDIA RTX 4090 GPU 的 Ubuntu 22.04 平台上完成. 网络采用交叉熵损失作为语义分割任务的优化目标. 训练阶段使用随机旋转、尺度扰动和高斯噪声注入等数据增强策略, 以提升模型的鲁棒性与泛化能力. 优化器选用 AdamW, 初始学习率设为  $1 \times 10^{-4}$ , 权重衰减系数为 0.05, 并采用余弦退火策略动态调整学习率. 该配置经在  $[10^{-6}, 10^{-2}]$  对数空间中的超参数搜索确定, 在收敛速度与分割精度之间取得最佳平衡. 总训练轮数为 100, 批次大小设为 16.

为定量评估点云分割方法的性能, 本文采用整体精度 (overall accuracy, OA)、平均准确率 (mean accuracy, mAcc) 以及平均交并比 (mean intersection over union, mIoU) 三类标准评价指标.

整体精度用于衡量所有类别中分类正确点的总体比例, 其定义为

$$OA = \frac{N_{\text{correct}}}{N_{\text{total}}} \quad (15)$$

其中,  $N_{\text{correct}}$  为正确分类的点数,  $N_{\text{total}}$  为点云中的总点数. OA 能够反映模型的整体分类精度.

平均准确率用于衡量各类别分类精度的均值, 其定义为

$$mAcc = \frac{1}{C} \sum_{c=1}^C \frac{N_c^{\text{correct}}}{N_c^{\text{total}}} \quad (16)$$

其中,  $C$  为类别总数,  $N_c^{\text{correct}}$  表示类别  $c$  中正确分类的点数,  $N_c^{\text{total}}$  表示该类别的总点数. mAcc 能够更均衡地反映模型在不同类别上的表现, 避免因类别数量差异过大而产生的评价偏差.

交并比 (intersection over union, IoU) 是衡量分割精度的重要指标, 反映模型在识别目标和定位边界时的准确性, 其计算式为

$$IoU_i = \frac{TP_i}{TP_i + FP_i + FN_i} \quad (17)$$

其中,  $TP_i$ 、 $FP_i$  和  $FN_i$  分别表示类别  $i$  的真阳性、假阳性和假阴性样本数.

平均交并比定义为所有类别 IoU 的平均值, 用于综合评价分割模型的整体性能, 其计算式为

$$mIoU = \frac{1}{C} \sum_{c=1}^C IoU_c \quad (18)$$

### 2.3 配电网场景语义分割实验

为系统验证所提方法在复杂场景下的分割精度与鲁棒性, 本文选取多个具有代表性的点云语义分割模型进行对比实验, 涵盖 KPConv<sup>[31]</sup>、PointNext-XL<sup>[32]</sup>、PointMetaBase-XL<sup>[33]</sup>、DeLA<sup>[34]</sup>、PTv3<sup>[23]</sup>、

表 1 配电网场景点云语义分割实验 (%)  
Table 1 Experiment on semantic segmentation of distribution network point cloud (%)

方法	OA	mAcc	mIoU	背景 IoU	电力线 IoU	电力杆塔 IoU	参数量 (M)
DeepGCN <sup>[19]</sup>	98.26	71.29	78.92	98.20	63.10	75.46	3.60
DGCNN <sup>[20]</sup>	98.89	78.88	83.36	99.03	62.13	88.92	1.30
PointNet++ <sup>[14]</sup>	98.40	86.04	84.75	99.62	67.48	87.14	<b>1.00</b>
KPCConv <sup>[31]</sup>	<b>98.90</b>	87.91	85.51	<b>99.90</b>	65.71	90.91	15.00
PointNext-XL <sup>[32]</sup>	98.27	91.40	88.54	98.65	74.72	92.25	41.60
PTv2 <sup>[22]</sup>	98.36	92.63	88.42	99.28	80.04	85.93	11.30
PointMetaBase-XL <sup>[33]</sup>	98.38	94.21	93.62	99.11	92.35	89.40	15.30
DeLA <sup>[34]</sup>	96.87	95.34	93.65	96.89	92.69	91.36	7.00
DeLA + X-3D <sup>[35]</sup>	98.59	96.81	94.29	96.36	94.30	92.22	8.00
PTv3 <sup>[23]</sup>	98.64	97.11	94.37	96.56	94.42	92.12	—
PCM <sup>[36]</sup>	98.79	97.27	95.69	96.96	<b>96.17</b>	93.93	34.20
SSCNet (本文)	98.74	<b>97.99</b>	<b>96.20</b>	97.85	94.36	<b>96.40</b>	12.54

注: 加粗字体表示各指标的最优结果.

DeLA + X-3D<sup>[35]</sup> 和 PCM<sup>[36]</sup> 等近年来在点云语义分割领域表现突出的强基线方法. 表 1 汇总了各方法的定量评估指标, 图 6 展示了典型复杂场景下的分割可视化结果.

从整体性能来看, 本文方法在主要评价指标上取得最优结果, 其中, mIoU 达到 96.20%, OA 为 98.74%, mAcc 为 97.99%. 在类别层面, SSCNet 在电力杆塔类别上取得 96.40% 的 IoU, 在所有方法中最高; 在电力线类别上, 基于 Mamba 的 PCM<sup>[36]</sup> 获得

96.17% 的 IoU, 而 SSCNet 为 94.36%, 略低于 PCM<sup>[36]</sup>, 但在 mIoU 上优于 PCM<sup>[36]</sup>. 与 PointMetaBase-XL<sup>[33]</sup> 和 DeLA<sup>[34]</sup> 等代表性方法相比, 本文在电力线和电力杆塔两类关键结构上的 IoU 均有明显提升, 表明所提结构频谱联合建模在细长构件识别和塔线关系刻画方面更具优势.

图 6 的可视化结果进一步验证了本文方法的有效性. 在塔-线连接区域, PointNext-XL<sup>[32]</sup> 与 PointMetaBase-XL<sup>[33]</sup> 模型出现明显误分, 反映出依赖局

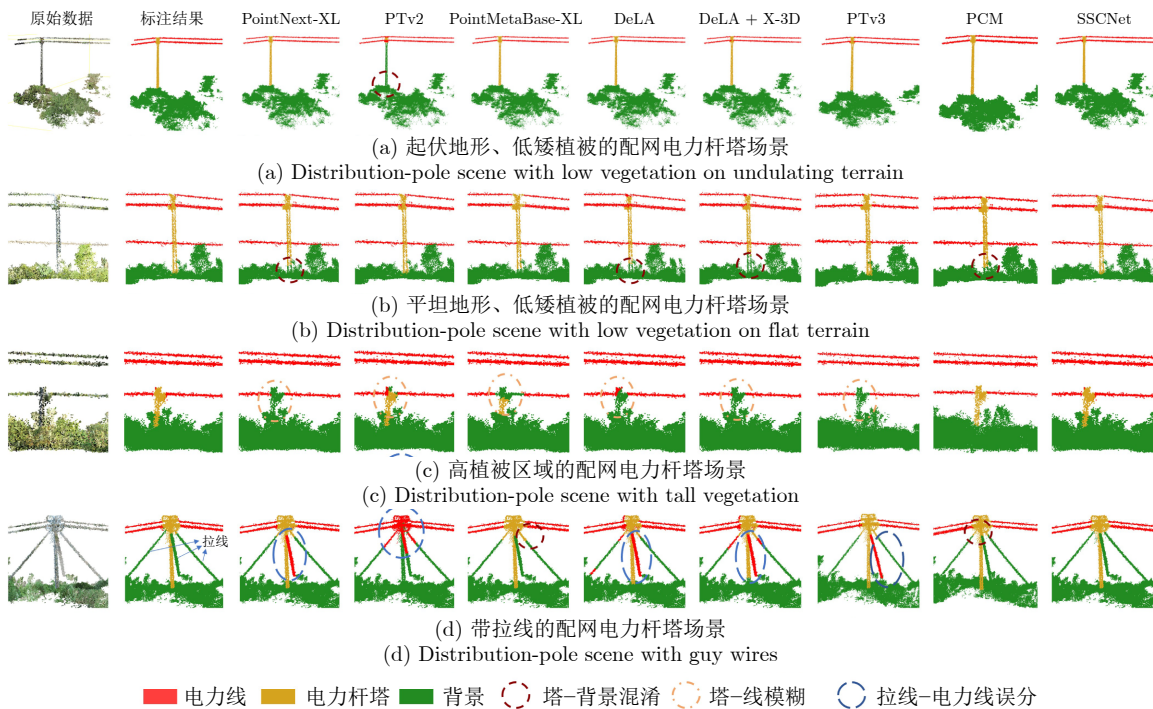


图 6 配电网场景点云语义分割结果可视化

Fig.6 Visualization of cloud semantic segmentation results for distribution network point cloud

部邻域建模难以捕捉连续且高频的边界结构, 而 PTV3<sup>[23]</sup> 与 PCM<sup>[36]</sup> 虽然在整体轮廓保持方面优于早期基线, 但在塔-线过渡区域仍可观察到局部边界模糊和少量误分现象. 本文方法借助频谱域的方向性建模能力, 通过构建 PRST, 将局部无序点集投影到以电力线局部主轴为基的极坐标系, 在角向上重排为一维序列并进行频谱分解, 从而在特征层面增大电力线与类别过渡区域的特征距离, 提升复杂场景下边界判别性, 有效保持电力线分割的连贯性. 在塔-背景交汇处, PTV2<sup>[22]</sup> 的结果易出现粘连或边界模糊, 表现出结构区分能力不足的问题; 所提方法则融合空间-频谱特征, 增强了跨尺度上下文建模能力, 分割边界更为清晰. 在植被密集区域, DeLA + X-3D<sup>[35]</sup> 与 DeLA<sup>[34]</sup> 方法存在拉线与电力线混淆的情况, 主要由于两类目标在空间结构上具有较高相似性, 且常同时分布于局部重叠区域. 相比之下, 本文引入跨分支交互机制, 提升结构判别能力, 使得分割结果与人工标注保持高度一致.

## 2.4 消融实验

### 2.4.1 数据预处理与子样本划分策略实验

为系统评估所提出的点云预处理与样本划分策略的有效性, 本文在自建数据集中选取三条具有代表性的山区配电线路 (S1 ~ S3) 开展实验. 首先, 利用结构引导的层级点云滤波方法对原始点云进行滤波, 剔除占比较高的背景点云, 如表 2 所示. 表 2 给出三条线路在滤波前后各类别点云数量及其占比的统计结果, 用于定量刻画预处理过程中背景类与电力杆塔、电力线等关键目标类点云分布的变化特征. 在不同场景下, 该策略可实现超过 70% 的背景点云滤除, 最高达到 98.9%, 大幅降低背景类对模型训练的干扰. 随后, 结合结构引导的样本划分策略, 将走廊区域划分为若干语义连续、结构完整的子样本, 为高效训练提供支持.

表 2 各场景滤波前后分类别点数统计 (单位: 万点)

Table 2 Category-wise point cloud statistics before and after filtering (Unit: 10<sup>4</sup> points)

场景	原始点云			滤波后点云			背景点 滤除率 (%)
	电力 线点	电力 杆塔点	背景点	电力 线点	电力 杆塔点	背景点	
S1	86.9	16.4	4890.0	86.1	15.7	1415.0	71.1
S2	67.9	1625.0	4042.0	65.7	1622.1	45.9	98.9
S3	117.6	1090.4	3162.0	116.8	1087.5	397.0	87.5

在此基础上, 本文构造三种数据处理配置, 用于系统评估预处理策略对分割性能与运行效率的影

响. 三种配置采用相同的网络结构与训练超参数, 仅在输入点云的预处理流程上存在差异: 1) 原始场景: 仅对原始点云进行坐标归一化等处理, 在完整场景上进行训练与测试, 不采用滤波与样本划分; 2) 仅滤波: 在原始场景的基础上, 引入结构引导的层级点云滤波, 利用滤波后点云进行训练与测试, 此时大比例背景点被滤除, 但线路走廊仍作为整体场景输入, 不进行走廊裁剪与子样本划分; 3) 滤波 + 样本划分: 在完成点云滤波的基础上, 进一步采用结构引导的样本划分与走廊裁剪策略, 将线路走廊划分为若干语义连续、结构完整的子样本, 并在这些子样本上进行训练与测试. 为验证预处理策略的普适性, 本文在上述三种配置下分别评估 SSC-Net、PTV3<sup>[23]</sup> 与基于 Mamba 结构的 PCM<sup>[36]</sup> 三种网络结构, 图 7 给出了不同配置下三种方法的 mIoU 与推理时长对比结果. 如图 7 所示, 经由“仅滤波”和“滤波 + 样本划分”等预处理后, 各方法的推理时间均显著下降, 而 mIoU 整体呈小幅提升或基本保持稳定; 其中 PTV3<sup>[23]</sup> 依托其更高效的特征提取结构, 在不同配置下均表现出较低的推理时间, 而 SSCNet 在保持最高分割精度的同时仍具备较高的推理效率, 表明所提预处理流程与网络结构在复杂走廊场景中具有良好的综合性能.

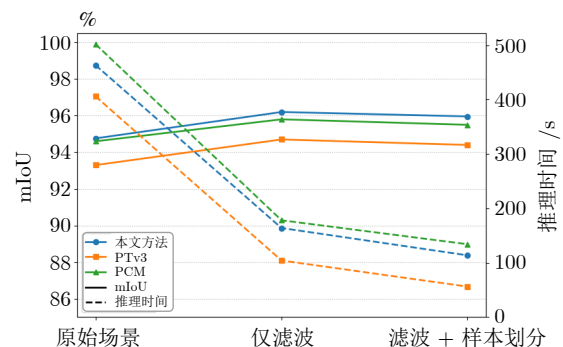


图 7 不同处理阶段下分割精度与运行时间的对比  
Fig. 7 Comparison of segmentation accuracy and runtime at different processing stages

### 2.4.2 模块消融实验

为深入分析所提出模块对整体性能的贡献, 本文在自建配电网数据集上进行消融实验, 评估 PRST 与 BGF 的作用. 实验设计包含四种配置: 1) 未引入 PRST 与 BGF 的基线模型, 仅依赖空间几何特征; 2) 仅引入 BGF, 频谱支路输入由空间支路特征替代; 3) 仅引入 PRST, 空间与频谱特征通过加权策略融合; 4) 同时引入 PRST 与 BGF 的完整模型.

表 3 展示了不同模块配置下的分割性能, PRST 的引入有效提升了网络对电力线类目标的结

构辨识能力,其频谱转换机制能够强调细长结构在角向的高频分布特征,有助于提升电力线的分类边界清晰度. BGF 模块虽然不直接参与局部结构建模,但通过在空间与频谱分支之间建立门控融合路径,实现跨尺度特征的动态平衡,显著改善了类别过渡区域的响应一致性. 在完整配置中,两模块联合部署后可观察到整体性能进一步提升. PRST 输出的边界特征经由 BGF 结构中位置依赖的门控机制进行强化,从而在无需引入额外计算复杂度的前提下增强类别分割能力. 该结果表明, PRST 提供的结构先验在分支融合过程中得以有效保留并利用,形成以频谱特征为基础的结构引导融合机制.

表 3 消融实验结果 (%)

Table 3 The ablation experiment results (%)

方法	PRST	BGF	OA	mIoU	mAcc
1			98.12	94.13	91.74
2	✓		98.57	95.86	96.84
3		✓	98.78	95.47	93.06
4	✓	✓	<b>98.74</b>	<b>96.20</b>	<b>97.99</b>

图 8 所示的特征响应可视化展示了不同模块配置在结构建模与边界感知方面的差异. 基线模型(图 8(a))在电力线和塔-背景过渡区域激活弱且不连续,反映出空间特征对结构细节建模的局限性. 引入 PRST(图 8(b))后,电力线方向激活增强,结构一致性显著提升,说明频谱建模有助于捕捉细长

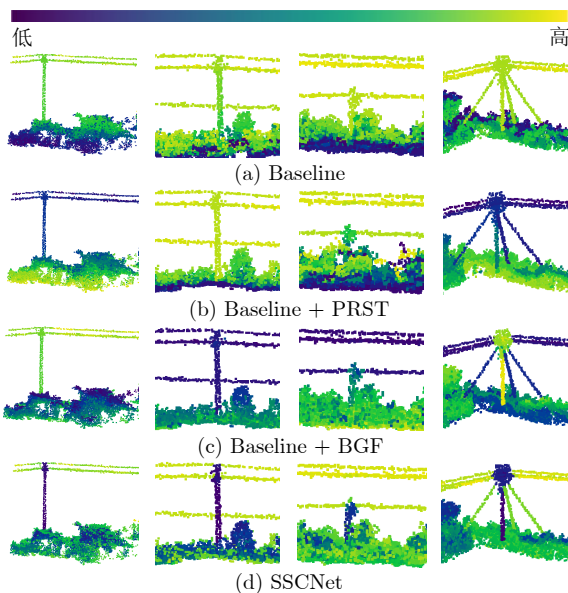


图 8 不同配置下的特征激活热图

Fig. 8 Feature activation heat maps under different configurations

结构的几何连续性. BGF 模块(图 8(c))则在边界区域形成更清晰的响应,缓解类别混叠问题. 完整配置(图 8(d))结合两者优势,证明了频谱特征提取与门控融合机制的有效性,能够共同增强对几何结构与语义边界的表征能力.

## 2.5 模型泛化性验证

为验证 SSCNet 在非配电网场景下的有效性,本文在标准室内点云数据集 S3DIS 上进行测试. 该数据集包含 6 个区域、271 间房间,覆盖 13 类典型室内目标,具有结构密集和语义分布复杂等特点. 实验采用 Area-5 划分策略,以 Area-5 区域作为测试集,其余区域用于训练.

表 4 汇总了多种代表性方法在 S3DIS 数据集上的语义分割性能. 如表 4 所示, SSCNet 在 mIoU 和 mAcc 两项核心指标上均达到当前最优,体现出良好的跨场景泛化能力. 值得强调的是,尽管该模型为配电网点云设计,其 PRST 与 BGF 模块在复杂室内环境中仍展现出稳定鲁棒性. 与 PTV2<sup>[22]</sup> 相比, SSCNet 的 mIoU 提升约 2.4%,且在参数规模明显更小的情况下实现更优精度;相较 DeLA 与其扩展 X-3D 结构, SSCNet 同样在保持轻量的前提下获得更优整体性能. PTV3<sup>[23]</sup> 与 PCM<sup>[36]</sup> 分别引入高效注意力机制与 Mamba 架构,具有较强建模能力,但在综合指标上仍略逊于 SSCNet,进一步验证了本文方法在频谱建模和门控融合方面的结构有效性与适应性.

表 4 主流方法在 S3DIS 数据集上的对比结果

Table 4 Comparison of mainstream methods on the S3DIS dataset

方法	参数量 (M)	OA (%)	mAcc (%)	mIoU (%)
PointNet++ <sup>[14]</sup>	1.0	83.0	—	53.5
DGCNN <sup>[20]</sup>	1.3	—	—	47.9
KPConv <sup>[31]</sup>	15.0	—	72.8	67.1
PointNext-XL <sup>[32]</sup>	41.0	91.0	77.2	71.1
PTV1 <sup>[37]</sup>	—	90.8	76.5	70.4
PTV2 <sup>[22]</sup>	11.3	91.6	78.0	72.7
PointMetaBase-XL <sup>[33]</sup>	15.3	90.6	—	71.5
DeLA <sup>[34]</sup>	7.0	92.2	80.0	74.1
DeLA + X-3D <sup>[35]</sup>	8.0	92.2	80.1	74.3
PTV3 <sup>[23]</sup>	—	—	—	74.7
PCM <sup>[36]</sup>	34.2	<b>92.9</b>	81.6	74.1
SSCNet	12.5	92.3	<b>82.1</b>	<b>75.1</b>

## 3 结束语

针对配电网走廊点云语义分割任务中存在的结

构目标分割精度不足与处理效率瓶颈, 本文提出结构频谱感知框架 SSAF. 该框架通过结构引导样本划分与频谱增强建模两条路径, 在保持结构连续性与边界清晰度的前提下, 有效提升了点云语义分割的精度与稳定性.

具体而言, 数据预处理阶段提出基于几何统计与空间拓扑的自适应滤波与结构感知划分策略, 实现大规模点云的语义保持与冗余压缩. 语义建模阶段, 设计空谱协同语义分割网络 SSCNet, 通过构建 PRST 和 BGF 模块, 在编码器中引入旋转不变的频谱建模与双向门控融合机制, 增强对方向性目标与复杂结构区域的识别能力.

在真实配电网数据集上, SSCNet 在多个结构类与全局指标上取得最优性能, 显示出良好的结构适应性与泛化能力. 随着模型精度日趋饱和, 未来工作将重点聚焦于网络压缩、模型轻量化与边缘端部署, 进一步提升系统在资源受限场景下的实用性及响应能力.

### 参考文献

- Shen Y Q, Huang J J, Wang J G, Jiang J D, Li J X, Ferreira V. A review and future directions of techniques for extracting powerlines and pylons from LiDAR point clouds. *International Journal of Applied Earth Observation and Geoinformation*, 2024, **132**: Article No. 104056
- Jung J, Che E Z, Olsen M J, Shafer K C. Automated and efficient powerline extraction from laser scanning data using a voxel-based subsampling with hierarchical approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, **163**: 343–361
- Liu X Y, Miao X R, Jiang H, Chen J, Wu M, Chen Z H. Tower masking MIM: A self-supervised pretraining method for power line inspection. *IEEE Transactions on Industrial Informatics*, 2024, **20**(1): 513–523
- Wang Fei-Ran, Han Geng, Guo Xin-Yang, Shi Chao-Yang, Wang Jin. Segmentation and clearance inspections on overhead transmission powerline corridor based on LiDAR point clouds. *Bulletin of Surveying and Mapping*, 2024(5): 133–137 (王斐然, 韩庚, 郭昕阳, 石朝阳, 王金. 激光雷达数据下架空输电线路点云场景分割及净空入侵检测. 测绘通报, 2024(5): 133–137)
- Kim H B, Sohn G. 3D classification of power-line scene from airborne laser scanning data using random forests. In: Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Saint-Mandé, France: ISPRS, 2010. 126–132
- Lehtomäki M, Kukko A, Matikainen L, Hyyppä J, Kaartinen H, Jaakkola A. Power line mapping technique using all-terrain mobile laser scanning. *Automation in Construction*, 2019, **105**: Article No. 102802
- Fischler M A, Bolles R C. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 1981, **24**(6): 381–395
- Shen X J, Qin C, Du Y, Yu X L, Zhang R. An automatic extraction algorithm of high voltage transmission lines from airborne LiDAR point cloud data. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2018, **26**(4): 2043–2055
- Zhu S, Li Q, Zhao J W, Zhang C G, Zhao G, Li L, et al. A deep-learning-based method for extracting an arbitrary number of individual power lines from UAV-mounted laser scanning point clouds. *Remote Sensing*, 2024, **16**(2): Article No. 393
- Maturana D, Scherer S. VoxNet: A 3D convolutional neural network for real-time object recognition. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Hamburg, Germany: IEEE, 2015. 922–928
- Shan Xuan-Yang, Sun Zhan-Li, Zeng Zhi-Gang. RFNet: Convolutional neural network for 3D point cloud classification. *Acta Automatica Sinica*, 2023, **49**(11): 2350–2359 (单铨洋, 孙战里, 曾志刚. RFNet: 用于三维点云分类的卷积神经网络. 自动化学报, 2023, **49**(11): 2350–2359)
- Lu Bin, Fan Xiao-Ming. Research on 3D point cloud skeleton extraction based on improved adaptive K-means clustering. *Acta Automatica Sinica*, 2022, **48**(8): 1994–2006 (鲁斌, 范晓明. 基于改进自适应 K 均值聚类的三维点云骨架提取的研究. 自动化学报, 2022, **48**(8): 1994–2006)
- Qi C R, Su H, Mo K C, Guibas L J. PointNet: Deep learning on point sets for 3D classification and segmentation. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA: IEEE, 2017. 77–85
- Qi C R, Yi L, Su H, Guibas L J. PointNet++: Deep hierarchical feature learning on point sets in a metric space. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017. 5105–5114
- Dong J H, Chen H, Chen S H, Zhao Y G, Yang N. PSFE-Net: Semantic segmentation network for airborne LiDAR transmission corridor scenes inspection. In: Proceedings of the 9th Asia Conference on Power and Electrical Engineering (ACPEE). Shanghai, China: IEEE, 2024. 1538–1542
- Liu X N, Shuang F, Li Y, Zhang L Q, Huang X W, Qin J C. SS-IPLE: Semantic segmentation of electric power corridor scene and individual power line extraction from UAV-based LiDAR point cloud. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, **16**: 38–50
- Huang Zheng, Gu Xu, Wang Hong-Xing, Zhang Xing-Wei, Zhang Xin. Semantic segmentation model for transmission tower point cloud based on improved PointNet++. *Electric Power*, 2023, **56**(3): 77–85 (黄郑, 顾徐, 王红星, 张星炜, 张欣. 基于改进 PointNet++ 的输电电力杆塔点云语义分割模型. 中国电力, 2023, **56**(3): 77–85)
- Li W, Luo Z P, Xiao Z L, Chen Y P, Wang C, Li J. A GCN-based method for extracting power lines and pylons from airborne LiDAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: Article No. 5700614
- Li G H, Müller M, Thabet A, Ghanem B. DeepGCNs: Can GCNs go as deep as CNNs? In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, South Korea: IEEE, 2019. 9266–9275
- Wang Y, Sun Y B, Liu Z W, Sarma S E, Bronstein M M, Solomon J M. Dynamic graph CNN for learning on point clouds. *ACM Transactions on Graphics*, 2019, **38**(5): Article No. 146
- Li Jian, Wang Jian, Wang Lei, Li Min, Yang Li-Ke, Zhao Yi-Long. Dual attention for power corridor point cloud semantic segmentation. *Bulletin of Surveying and Mapping*, 2025(4): 127–133 (李建, 王健, 王雷, 李敏, 杨立克, 赵艺龙. 双重注意力机制的电力走廊点云语义分割. 测绘通报, 2025(4): 127–133)
- Wu X Y, Lao Y X, Jiang L, Liu X H, Zhao H S. Point transformer V2: Grouped vector attention and partition-based pooling. In: Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc., 2022. Article No. 2415

- 23 Wu X Y, Jiang L, Wang P S, Liu Z J, Liu X H, Qiao Y, et al. Point transformer V3: Simpler, faster, stronger. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2024. 4840–4851
- 24 Bu L B, Wang Y F, Ma Q M, Hou Z W, Wang R, Bu F L. Deep hierarchical learning on point clouds in feature space. *Neurocomputing*, 2025, **630**: Article No. 129647
- 25 Liu D Z, Hu W, Li X. Point cloud attacks in graph spectral domain: When 3D geometry meets graph signal processing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, **46**(5): 3079–3095
- 26 Wen C, Long J Z, Yu B S, Tao D C. PointWavelet: Learning in spectral domain for 3-D point cloud analysis. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, **36**(3): 4400–4412
- 27 Rizaldy A, Gloaguen R, Fassnacht F E, Ghamisi P. HyperPointFormer: Multimodal fusion in 3-D space with dual-branch cross-attention transformers. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, **18**: 21254–21274
- 28 Liang D K, Feng T R, Zhou X, Zhang Y M, Zou Z K, Bai X. Parameter-efficient fine-tuning in spectral domain for point cloud learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, **47**(12): 10949–10966
- 29 Yang Y Y, Li W, Ao S, Xu Q S, Yu S S, Guo Y, et al. RALoc: Enhancing outdoor LiDAR localization via rotation awareness. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Honolulu, USA: IEEE, 2025. 3304–3313
- 30 Zhang W M, Qi J B, Wan P, Wang H T, Xie D H, Wang X Y, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 2016, **8**(6): Article No. 501
- 31 Thomas H, Qi C R, Deschaud J E, Marcotegui B, Goulette F, Guibas L J. KPConv: Flexible and deformable convolution for point clouds. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, South Korea: IEEE, 2019. 6410–6419
- 32 Qian G C, Li Y C, Peng H W, Mai J J, Hammoud H A A K, Elhoseiny M, et al. PointNeXt: Revisiting PointNet++ with improved training and scaling strategies. In: Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc., 2022. Article No. 1685
- 33 Lin H J, Zheng X W, Li L J, Chao F, Wang S S, Wang Y, et al. Meta architecture for point cloud analysis. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, Canada: IEEE, 2023. 17682–17691
- 34 Yang W K, Lu X H, Chen B J, Lin C L, Bao X Y, Liu W Q, et al. DeLA: An extremely faster network with decoupled local aggregation for large scale point cloud learning. *International Journal of Applied Earth Observation and Geoinformation*, 2024, **135**: Article No. 104255
- 35 Sun S F, Rao Y M, Lu J W, Yan H B. X-3D: Explicit 3D structure modeling for point cloud recognition. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2024. 5074–5083
- 36 Zhang T, Yuan H B, Qi L, Zhang J N, Zhou Q Y, Ji S P, et al. Point cloud mamba: Point cloud learning via state space model. In: Proceedings of the 39th AAAI Conference on Artificial Intelligence. Philadelphia, USA: AAAI Press, 2025. 10121–10130
- 37 Zhao H S, Jiang L, Jia J Y, Torr P, Koltun V. Point transformer. In: Proceedings of the IEEE/CVF International Confer-

ence on Computer Vision (ICCV). Montreal, Canada: IEEE, 2021. 16239–16248



**唐友源** 长沙理工大学人工智能学院硕士研究生。2023 年获得湘南学院学士学位。主要研究方向为点云智能感知。E-mail: [tangyouyuan@stu.csust.edu.cn](mailto:tangyouyuan@stu.csust.edu.cn) (**TANG You-Yuan** Master student at the School of Artificial Intelligence, Changsha University of Science and Technology. He received his bachelor degree from Xiangnan University in 2023. His main research interest is point cloud intelligent perception.)




**张辉** 湖南大学人工智能与机器人学院教授。2007 年获得湖南大学博士学位。主要研究方向为数据分析, 图像处理和机器人控制。本文通信作者。E-mail: [zhanghui1983@hnu.edu.cn](mailto:zhanghui1983@hnu.edu.cn) (**ZHANG Hui** Professor at the School of Artificial Intelligence and Robotics, Hunan University. He received his Ph.D. degree from Hunan University in 2007. His research interests include data analysis, image processing, and robot control. Corresponding author of this paper.)



**杜瑞** 湖南大学人工智能与机器人学院博士研究生。2020 年获得湘潭大学硕士学位。主要研究方向为数据分析, 图像处理。E-mail: [durui@hnu.edu.cn](mailto:durui@hnu.edu.cn) (**DU Rui** Ph.D. candidate at the School of Artificial Intelligence and Robotics, Hunan University. He received his master degree from Xiangtan University in 2020. His research interests include data analysis and image processing.)



**张恺宁** 湖南大学人工智能与机器人学院助理教授。2025 年获得武汉大学通信与信息系统专业博士学位。主要研究方向为 3D 视觉和多模态感知。E-mail: [carney@hnu.edu.cn](mailto:carney@hnu.edu.cn) (**ZHANG Kai-Ning** Assistant professor at the School of Artificial Intelligence and Robotics, Hunan University. She received her Ph.D. degree in communication and information systems from Wuhan University in 2025. Her research interests include 3D vision and multimodal perception.)




**曹云康** 湖南大学人工智能与机器人学院助理教授. 2025 年获得华中科技大学机械工程专业博士学位. 主要研究方向为复杂场景下的工业视觉检测与识别, 工业基础模型及工业具身智能.  
E-mail: [caoyunkang@hnu.edu.cn](mailto:caoyunkang@hnu.edu.cn)

(**CAO Yun-Kang** Assistant professor at the School of Artificial Intelligence and Robotics, Hunan University. He received his Ph.D. degree in mechanical engineering from Huazhong University of Science and Technology in 2025. His research interests include industrial vision detection and recognition in complex scenarios, industrial foundation models, and industrial embodied intelligence.)



**别克扎提·巴合提** 湖南大学人工智能与机器人学院博士研究生. 2020 年获得英国克兰菲尔德大学硕士学位. 主要研究方向为信号分析, 时间序列分析.  
E-mail: [bbiekezati@hnu.edu.cn](mailto:bbiekezati@hnu.edu.cn)

(**BIEKEZATI Baheti** Ph.D. candidate at the School of Artificial Intelligence and Robotics, Hunan University. He received his master degree from Cranfield University in 2020. His research interests include signal analysis and time series analysis.)



**陈厚权** 湖南大学人工智能与机器人学院博士研究生. 2022 年获得中南林业科技大学计算机信息与工程学院学士学位. 主要研究方向为电力场景的多模态技术.  
E-mail: [chq@hnu.edu.cn](mailto:chq@hnu.edu.cn)

(**CHEN Hou-Quan** Ph.D. candidate at the School of Artificial Intelligence and Robotics, Hunan University. He received his bachelor degree from the School of Computer and Information Engineering, Central South University of Forestry and Technology in 2022. His research interests include multimodal technologies for power-system applications.)



**王耀南** 中国工程院院士, 湖南大学人工智能与机器人学院教授. 1995 年获得湖南大学博士学位. 主要研究方向为数据分析, 智能控制和图像处理.  
E-mail: [yaonan@hnu.edu.cn](mailto:yaonan@hnu.edu.cn)

(**WANG Yao-Nan** Academician at Chinese Academy of Engineering, professor at the School of Artificial Intelligence and Robotics, Hunan University. He received his Ph.D. degree from Hunan University in 1995. His research interests include data analysis, intelligent control, and image processing.)