北京林业大学学报
JOURNAL OF BEIJING FORESTRY UNIVERSITY

UFNet：基于移动激光扫描（MLS）点云的景观森林高大乔木林下干扰物滤除方法

许朝阳 蒋含笑 张礼 云挺

UFNet: an intelligent filtering approach for understory disturbance of tall trees in landscape forests using Mobile Laser Scanning (MLS) point clouds

Xu Zhaoyang, Jiang Hanxiao, Zhang Li, Yun Ting

引用本文:
许朝阳, 蒋含笑, 张礼, 云挺. UFNet：基于移动激光扫描（MLS）点云的景观森林高大乔木林下干扰物滤除方法[J]. 北京林业大学学报, 2026, 48(7):127–138. doi: 10.12171/j.1000–1522.20250285
Xu Zhaoyang, Jiang Hanxiao, Zhang Li, Yun Ting. UFNet: an intelligent filtering approach for understory disturbance of tall trees in landscape forests using Mobile Laser Scanning (MLS) point clouds[J]. Journal of Beijing Forestry University, 2026, 48(7):127–138. doi: 10.12171/j.1000–1522.20250285

在线阅读 View online: https://doi.org/10.12171/j.1000–1522.20250285

您可能感兴趣的其他文章

Articles you may be interested in

基于级联循环网络的林木生长参数预测

Prediction of tree growth parameters based on cascaded recurrent network

北京林业大学学报, 2023, 45(8): 94–108. https://doi.org/10.12171/j.1000–1522.20230027

基于深度学习和上采样的杉木单木枯损模型构建

High–precision individual tree mortality prediction for Chinese fir using deep learning and oversampling

北京林业大学学报, 2025, 47(12): 39–47. https://doi.org/10.12171/j.1000–1522.20250103

面向钻蛀振动实时侦听的深度学习模型压缩

Deep learning model compression for real–time listening of boring vibration

北京林业大学学报, 2021, 43(6): 92–100. https://doi.org/10.12171/j.1000–1522.20200100

基于深度学习的城市滨河绿道景观视觉感知评价研究

Research on visual perception evaluation of urban riverside greenway landscape based on deep learning

北京林业大学学报, 2021, 43(12): 93–104. https://doi.org/10.12171/j.1000–1522.20210175

基于无人机激光雷达点云数据估算红树林覆盖度

Estimating mangrove forest coverage based on unmanned aerial vehicle (UAV) LiDAR point cloud data

北京林业大学学报, 2025, 47(2): 143–151. https://doi.org/10.12171/j.1000–1522.20240185

基于Mask R–CNN和迁移学习的无人机遥感影像杉木单木树冠提取

UAV remote sensing image extraction of single tree crown of Chinese fir based on Mask R–CNN and transfer learning

北京林业大学学报, 2024, 46(3): 153–166. https://doi.org/10.12171/j.1000–1522.20210343

DOI:10.12171/j.1000−1522.20250285

UFNet: 基于移动激光扫描（MLS）点云的景观森林高大乔木林下干扰物滤除方法

许朝阳[1]　蒋含笑[2]　张　礼[1]　云　挺[1,3]

（1. 南京林业大学信息科学技术学院、人工智能学院，江苏 南京 210037；2. 佐治亚理工学院计算学院，美国 佐治亚州亚特兰大，GA 30332；3. 南京林业大学林草学院、水土保持学院，江苏 南京 210037）

摘要:【目的】高大乔木的结构稳定性是景观森林可持续管理的核心，其精准监测与信息提取已成为城市绿地管理的关键任务。然而，林下支撑物与灌木等干扰物常遮挡或混淆主干点云，制约林分信息获取精度。针对这一问题，本研究提出一种林下干扰物自动滤除方法，以获取清晰、准确的高大乔木主干结构信息，支撑城市森林数字化监测与精细化管理。**【方法】**本文提出一种基于移动激光扫描（MLS）点云的智能滤除方法 UFNet。为准确提取体素内的局部几何特征，该方法首先通过体素特征编码模块实现原始点云的特征增强；随后，利用子流形稀疏卷积模块在保持数据稀疏性的同时高效提取深层语义信息，避免特征在复杂林区场景下的无效扩散；最后，通过层次化的编码器−解码器结构实现多尺度特征融合，以增强对细小干扰物与乔木主干边界的感知能力，实现干扰物的精准自动滤除。**【结果】**UFNet 在复杂林下环境中展现出稳定的语义分割性能，能够有效区分干扰物与树干。在上海植物园林木样地的实验中，UFNet 整体表现为精度 88.72%、召回率 88.65%、F_1 88.69%、交并比 79.67%。与 5 种深度学习方法相比，UFNet 的精度、召回率、F_1、交并比分别提升 3.48 ~ 10.21、5.04 ~ 11.37、4.27 ~ 10.80 和 6.63 ~ 15.88 个百分点。干扰物滤除后，点云结构显著清晰，单株分割的 F_1 分数提升至 94.64%，交并比提升至 89.83%。**【结论】**UFNet 具备出色的林下干扰物滤除能力，可有效提升高大乔木结构信息的获取精度，可为以乔木为主体的城市景观森林开展三维建模与精细化管理提供关键技术支撑。

关键词：城市森林；移动激光扫描（MLS）；林下干扰物滤除；点云语义分割；子流形稀疏卷积；层次化编码器−解码器；深度学习；单木分割

中图分类号：S771.8；TP391.41　　**文献标志码：**A　　**文章编号：**1000−1522(2026)07−0127−12

引文格式：许朝阳，蒋含笑，张礼，等. UFNet：基于移动激光扫描（MLS）点云的景观森林高大乔木林下干扰物滤除方法[J]. 北京林业大学学报，2026，48(7)：127−138. Xu Zhaoyang, Jiang Hanxiao, Zhang Li, et al. UFNet: an intelligent filtering approach for understory disturbance of tall trees in landscape forests using Mobile Laser Scanning (MLS) point clouds[J]. Journal of Beijing Forestry University, 2026, 48(7): 127−138.

UFNet: an intelligent filtering approach for understory disturbance of tall trees in landscape forests using Mobile Laser Scanning (MLS) point clouds

Xu Zhaoyang[1]　Jiang Hanxiao[2]　Zhang Li[1]　Yun Ting[1,3]

(1. College of Information Science and Technology, College of Artificial Intelligence, Nanjing Forestry University, Nanjing 210037, Jiangsu, China;
2. College of Computing, Georgia Institute of Technology, Atlanta, GA 30332, USA;
3. College of Forestry and Grassland, College of Soil and Water Conservation, Nanjing Forestry University, Nanjing 210037, Jiangsu, China)

收稿日期: 2025−07−25　**修回日期:** 2026−01−28

基金项目: 国家自然基金面上项目（32371876）。

第一作者: 许朝阳。主要研究方向：人工智能、智慧林业。Email：xuzhaoyang@njfu.edu.cn　地址：210037 江苏省南京市玄武区龙蟠路 159 号南京林业大学信息科学技术学院。

责任作者: 张礼，副教授。主要研究方向：人工智能、遥感图像、智慧林业。Email：lizhang@njfu.edu.cn　地址：同上。

本刊网址: https://j.bjfu.edu.cn；https://journal.bjfu.edu.cn

Abstract: [**Objective**] The structural stability of tall trees is central to the sustainable management of landscape forests, and their precise monitoring and information extraction have become key tasks in urban green space management. However, understory clutter, such as supports and shrubs, often obscures or confuses trunk point clouds, limiting the accuracy of forest information acquisition. To address this issue, this study proposes an automatic understory clutter filtering method to obtain clear and accurate structural information of tall tree trunks, thereby supporting digital monitoring and refined management of urban forests. [**Method**] This paper presents UFNet, an intelligent filtering method based on MLS point clouds. To accurately extract local geometric features within voxels, the method first enhances the original point cloud features through a voxel feature encoding module. Subsequently, a submanifold sparse convolution module is employed to efficiently extract deep semantic information while preserving data sparsity, thus avoiding ineffective feature diffusion in complex forest scenes. Finally, a hierarchical encoder-decoder architecture is used to achieve multi-scale feature fusion, enhancing the perception of small clutter objects and tree trunk boundaries, thereby enabling precise automatic filtering of understory clutter. [**Result**] UFNet demonstrates robust semantic segmentation performance in complex understory environments, effectively distinguishing clutter from trunks. In experiments conducted in forest plots at the Shanghai Botanical Garden, UFNet achieved an overall precision of 88.72%, recall of 88.65%, F_1-score of 88.69%, and Intersection over Union (IoU) of 79.67%. Compared with five other deep learning methods, UFNet improved these four metrics by 3.48–10.21, 5.04–11.37, 4.27–10.80, and 6.63–15.88 percentage points, respectively. Following clutter filtering, the point cloud structure became markedly clearer, with the F_1-score for individual tree segmentation increasing to 94.64% and the IoU rising to 89.83%. [**Conclusion**] UFNet exhibits effective capability in understory clutter filtering and can effectively enhance the accuracy of structural information acquisition for tall trees. It provides critical technical support for 3D modeling and refined management of tree-dominated urban landscape forests.

Key words: urban forest; Mobile Laser Scanning (MLS); understory clutter filtering; point cloud semantic segmentation; submanifold sparse convolution; hierarchical encoder-decoder; deep learning; individual tree segmentation

随着城市生态文明建设的推进，景观森林作为城市公园生态系统中的重要组成部分，不仅在改善空气质量、调节局部气候、提供休闲空间等方面发挥着重要作用，也成为城市绿色基础设施精细化管理的关键对象。其中，高大乔木是维持生态功能与景观格局的主体，其结构稳定性与健康状况直接影响城市绿地的生态效益与景观价值。因此，景观森林管理的核心任务之一就是对高大乔木的精准监测与信息提取[1]。近年来，激光雷达（LiDAR）技术因其具备穿透冠层、获取三维结构信息的能力，已广泛应用于城市公园与林业场景中的点云数据采集与分析。相比于光学影像遥感，激光雷达不仅提供了更高的空间精度，还能获取地形起伏、树木高度、胸径等关键参数，为林分结构的量化建模与个体树木的自动识别提供了技术基础。然而，景观森林高大乔木林下区域往往存在支撑物、灌木、低矮植被等干扰物，这些干扰物严重影响了单株树木提取的准确性，因此，获取清晰、完整的点云数据对于高大乔木的单株分割和林分因子提取具有重要意义，而林下干扰物的自动滤除正是实现这一目标的关键环节。

目前，国内外学者围绕基于激光雷达的林下干扰物滤除展开了一系列的研究，相关方法主要集中在传统机器学习框架下。例如，结合形态学滤波先分离地面与非地面点，再利用比较最短路径算法对非地面点云进行两轮分割处理，可以实现森林点云中乔木层、灌木层和地面层的三层结构分类[2]，但该方法在城市公园的复杂地形下聚类效果不够稳定。利用点云空间邻域特征提取主方向信息，结合欧氏聚类进一步筛选主干区域，可以有效滤除林下低矮植被点云[3]，但该方法对倾斜主干、交错树木的适应性较差。通过点云法向量与支持向量机进行初步分类，再结合 RANSAC 圆柱体模型拟合与自适应 DBSCAN 聚类，可实现复杂林区中乔灌的精细分离[4]，但该方法依赖人工选择特征，泛化能力差。近年来，基于深度学习的方法也被广泛引入林业场景，如单株分割[5]、树种识别[6]以及冠层分割[7]等多个关

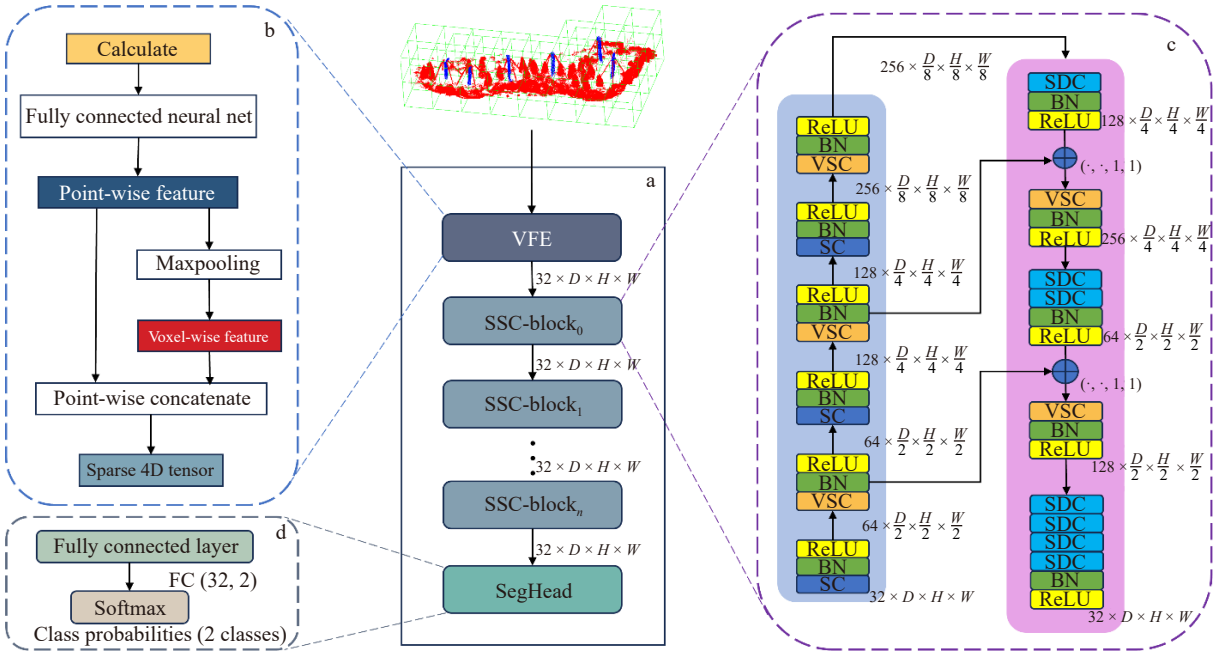
键任务，但是对城市景观森林中林下干扰物的自动识别与滤除关注较少。城市景观森林林下区域结构复杂，支撑物、灌木与主干在空间与形态上高度相似，尤其在主干倾斜、生长异常或交错遮挡等场景下，常规方法识别精度明显下降。

针对景观森林点云中高大乔木主干结构受林下干扰物遮挡、难以自动识别与滤除，现有深度学习研究多聚焦于单木分割而非干扰物滤除的问题。本研究拟提出一种景观森林林下干扰物自动滤除方法。核心架构采用体素特征编码模块[8]作为输入端模块，通过增强点间局部几何关系的表征，提升对支撑物、灌木等细碎目标的感知能力。在主干网络设计上，集成子流形稀疏卷积模块[9]与层次化编码器–解码器结构[10]，以适用于大规模点云的高效处理，兼顾局部几何特征提取与全局上下文依赖建模，从而在支撑物与树干高度相似的复杂场景下保持高分辨率的识别能力。本研究重点在于面向林下干扰场景的结构化集成与稀疏性管理策略，预期通过该方案显著提升高大乔木结构信息的提取精度，为后续单株分割以及城市景观森林的精细化管理提供可靠的技术支撑。

1　UFNet 的构建

1.1　UFNet 整体架构

本文提出的 UFNet 是一种基于体素的高性能点云语义分割网络，其核心架构遵循了 VoxelNet 定义的点云处理范式。为了解决 VoxelNet 在处理大规模景观森林数据时因密集卷积带来的计算冗余问题，UFNet 将原有的卷积中间层与 RPN（Region Proposal Network）部分改进为基于子流形稀疏卷积（Submanifold Sparse Convolution，SSC）的层次化编码器–解码器结构。这一改进在保持点云特征稀疏性的同时，增强网络对林下复杂干扰物的多尺度感知能力，其整体框架如图 1a 所示。输入的点云首先经过体素特征编码模块（Voxel Feature Encoding，VFE），具体结构见图 1b。该模块通过全连接网络对体素内点特征进行最大池化（Maxpooling）以提取局部上下文信息，并将其与原始点特征拼接，生成融合后的体素级表示，最终形成稀疏 4D 张量作为网络输入。主干网络由若干子流形稀疏卷积块（SSC-block）顺序堆叠而成，SSC-block 内部结构如图 1c 所示。每个均采用编码器–解码器结构，并从前一个 SSC-block 接收相同分辨率和特征通道数的输入表示，以保证整体结构的一致性与稳定性。图中各层特征张量的尺寸以 $C \times D \times H \times W$ 表示，其中 C 为通道数，D、H、W 分别对应张量在深度、高度与宽度方向的体素分辨率。在编码器阶段，UFNet 通过稀疏卷积（Sparse Convolution，SC）进行分辨率压缩，并交替引入有效稀疏卷积（Valid Sparse Convolution，VSC）以保持特征稀疏性与结构紧致性。在解码器阶段，利用稀疏反卷积（Sparse Deconvolution，SDC）逐层恢复特征分辨率，并继续使用有效稀疏卷积对解码特征进行细化处理，同时通过跳跃连接融合编码器的中低层特征，以提升空间细节恢复与上下文建模能



D、H、W 分别对应张量在深度、高度与宽度方向的体素分辨率。

图 1　UFNet 网络结构图

Fig. 1　UFNet network architecture diagram

力。最后通过全连接层(Fully Connected Layer，FC 层)与 Softmax 构成的语义分割头(SegHead)输出每个点的类别预测结果，其结构如图 1d 所示。

1.2 体素特征编码模块

在特征提取阶段，UFNet 改进了 VoxelNet 的体素特征编码逻辑。给定活跃体素，即非空体素，其对应的点集合记为$\boldsymbol{V}$，$\boldsymbol{V}=\left\{u_1,u_2,\ldots,u_nu_k=[x_k,y_k,z_k]^{\mathrm{T}}\in\mathbb{R}^3\right\}$，其中$[x_k,y_k,z_k]$表示每个点的三维坐标。对于每个活跃体素，首先计算所有点的局部均值作为体素的质心，记为(v_x, v_y, v_z)。将每个点相对于该质心的空间偏移量拼接至原始点属性中，构成增强的输入特征$\tilde{\boldsymbol{u}}_k$。

$$\tilde{\boldsymbol{u}}_k=\left[x_k,y_k,z_k,x_k-v_x,y_k-v_y,z_k-v_z\right] \tag{1}$$

不同于 VoxelNet 原型采用 7 维特征并堆叠多层 VFE 的设计，UFNet 针对不含强度信息的景观森林点云，将输入特征优化为上述 6 维表示，并采用单层编码路径以最大限度保留细碎干扰物的几何分辨率，避免特征过度平滑。

随后，增强特征$\tilde{u}_k$通过共享权重的全连接网络提取逐点特征。在获得逐点表示后，利用最大池化在体素内聚合生成全局特征，并通过 concatenate 函数将逐点特征与体素特征进行融合。最后，该模块通过哈希表记录活跃体素的空间坐标及其特征索引，构建出轻量化的稀疏 4D 张量。这种结构化表征仅保留有效信息，为后续子流形稀疏卷积的高效计算奠定了数据基础。

1.3 子流形稀疏卷积块

在 VoxelNet 的后续处理中，在经过卷积中间层处理后，4D 张量会被重塑为一个密集的 2D 特征图，其 RPN 部分由全卷积层组成。在特征传递与融合阶段，UFNet 针对 VoxelNet 传统卷积层显存占用大，感受野受限的痛点，引入了子流形稀疏卷积技术[9]，通过构建规则书管理点云的稀疏性。此外，本文通过引入层次化编码器−解码器结构进一步改进 VoxelNet 的单向特征链，实现深层语义信息与浅层空间细节的跨尺度对齐，显著提升在林下干扰物边缘处的分割效果。

具体而言，UFNet 通过配置步长 $s=2$，卷积核大小 $f=3$ 的 SC 算子，在压缩空间分辨率的同时，扩大感受野，从而捕获更丰富的语义上下文信息。不同于传统的密集卷积，该 SC 算子仅在感受野内存在输入体素的活跃点上产生输出，从而在下采样过程中维持点云的稀疏表征。通过在编码阶段逐步增加特征通道数并减小空间维度，网络能够从复杂的林下点云中抽象出具有判别性的高阶特征，为后续精准区分乔木主干与林下干扰物奠定基础。

在 SC 操作过程中，输出层的活跃体素集合$\boldsymbol{A}_{\mathrm{out}}$根据输入集合$\boldsymbol{A}_{\mathrm{in}}$与卷积核感受野偏移集合$\mathcal{F}$动态生成。

$$\boldsymbol{A}_{\mathrm{out}}=\bigcup\nolimits_{p_i\in\boldsymbol{A}_{\mathrm{in}}}\{p_i+\delta\mid\delta\in\mathcal{F}\},\mathcal{F}=\left\{-\left\lfloor\frac{f}{2}\right\rfloor,\cdots,\left\lfloor\frac{f}{2}\right\rfloor\right\}^d \tag{2}$$

式中：i 为输入特征矩阵的行索引，其对应的输入体素坐标记为$p_i\in\boldsymbol{A}_{\mathrm{in}}$；$\delta$表示偏移量，即感受野范围内所有体素与$p_i$的相对位置；$d$ 表示维度，这里为 3。随后，在规则书中记录其输入特征矩阵行索引与输出特征矩阵行索引的映射关系(R_δ)。

$$R_\delta=\{(i,j)\mid p_i+\delta=\boldsymbol{q}_j,p_i\in\boldsymbol{A}_{\mathrm{in}},\boldsymbol{q}_j\in\boldsymbol{A}_{\mathrm{out}},\delta\in\mathcal{F}\} \tag{3}$$

式中：j 为输出矩阵的行索引，其对应输出体素坐标记为$\boldsymbol{q}_j\in\boldsymbol{A}_{\mathrm{out}}$。

在 SC 操作过程中，位于特征边界且无法构成完整感受野的点将被忽略。如果感受野范围内至少存在一个输入体素$p_i\in\boldsymbol{A}_{\mathrm{in}}$，输出体素 q_j 将被激活，其特征由该感受野内的所有输入点的特征通过线性组合得到，具体公式为

$$\boldsymbol{F}_{\mathrm{out}}^{\mathrm{sc}}[j]=\sum\nolimits_{\delta\in\mathcal{F}}\sum\nolimits_{(i,j)\in R_\delta}\boldsymbol{W}_\delta\cdot\boldsymbol{F}_{\mathrm{in}}^{\mathrm{sc}}[i] \tag{4}$$

式中：$\boldsymbol{F}_{\mathrm{out}}^{\mathrm{sc}}[j]$表示输出特征矩阵中第 j 行对应的体素q_j的特征向量，在执行 SC 操作之前，需将输出特征矩阵初始化为全零矩阵，用于存储卷积计算结果；$\boldsymbol{F}_{\mathrm{in}}^{\mathrm{sc}}[i]$表示输入特征矩阵中第 i 行对应体素p_i的特征向量；W_δ表示卷积核在感受野偏移处的权重矩阵，整体卷积核权重构成一个五维张量$\boldsymbol{W}_\delta\in\mathbb{R}^{f\times f\times f\times m\times n}$。

为了防止 SC 操作引入过多新的活跃体素，破坏稀疏结构的紧致性，UFNet 在每一次 SC 操作之后使用步长 $s=1$，卷积核大小 $f=3$ 的 VSC 算子用于后续的特征提取[9]。在该过程中，网络通过直接复用输入层的哈希索引，确保卷积计算严格限制在原始活跃体素坐标处，而不生成新的活跃点。这种机制不仅消除了重新构造规则书的计算开销，更确保了特征提取始终聚焦于已激活的目标区域，有效避免了稀疏结构在深层网络中的无效扩散，从而更好地保留了林下细碎干扰物的空间几何特征。

在解码器阶段，本文通过 SDC 实现特征图的空间分辨率恢复。SDC 可视为对应 SC 操作的逆运算，其通过反向映射使输出活跃点与编码器对应层的原始输入活跃点精准对齐，在恢复分辨率的同时保持计算的紧致性。在每一级解码过程中，本文通过跳跃连接融合浅层局部特征与高阶语义特征，并依次通过 VSC 算子完成通道对齐与特征细化。这种结合 SDC 与 VSC 的解码方案，不仅提升了局部语义

的一致性，更增强了模型对景观森林中高大乔木与细碎支撑物边界的建模能力，为最终的点级语义预测提供了更具判别性的高质量特征。

2　UFNet 的实地验证

2.1　数据来源及处理

本文研究区域为上海植物园（图 2）。使用 LIBACKPACK DGC 50 移动激光扫描系统获得了植物园部分区域的点云数据，其点云密度为 500 点/m^3。其中有 4 片区域环境最为复杂。以松柏园为例，园内种植了超过 50 种裸子植物，主要树种包括雪松（*Cedrus deodara*）、榧树（*Torreya grandis*）等乔木，地形起伏呈丘陵状。本文将树高大于 6 m 的乔木作为主要研究对象，其林下区域的低矮幼树、草本植被、灌木及人工支撑物等被视为干扰物。干扰物高度主要分布从地表开始的 0～4 m 范围内（低矮幼树约 1～3 m，草本植被约 0～1 m，灌木约 0.5～2 m，支撑物约 1～4 m），基本在 0～6 m 林下区域内。按垂直高度 z 截取 0～6 m 的点云子集，该高度带对应城市园林作业与树木支撑设施的主要分布区间，不参与网络参数的动态调节。

对于下层的点云数据，首先使用地面插值算法将数字表面模型转换为冠层高度模型，以削弱地形起伏对点云高度结构的干扰；随后使用高斯滤波进行基础去噪，主要用于剔除悬浮点、孤立点等无效噪声数据。接着通过混合回归技术[11]将地面点去除，最后将其划分为体素网格，并加入了语义类别标注信息，其中红色点表示干扰物，蓝色点表示高大乔木主干，如图 3 所示。此外，本文使用了采集于南京林业大学校园后山区、中轴线小游园以及道路两侧的树木点云数据作为辅助数据集，该数据集使用和上海植物园相同设备采集，主要树种包括水杉

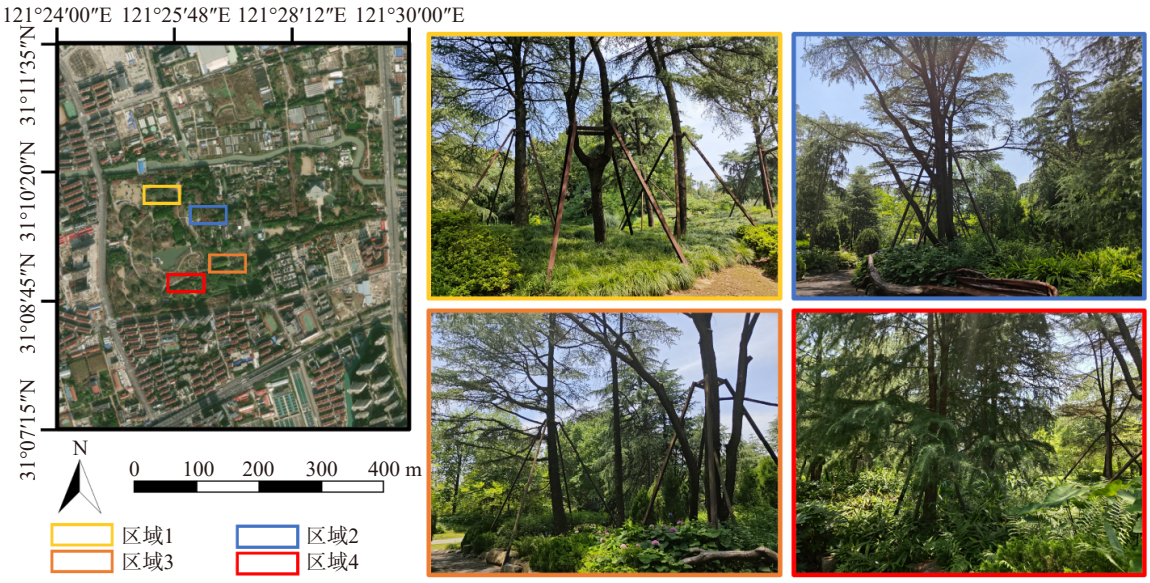
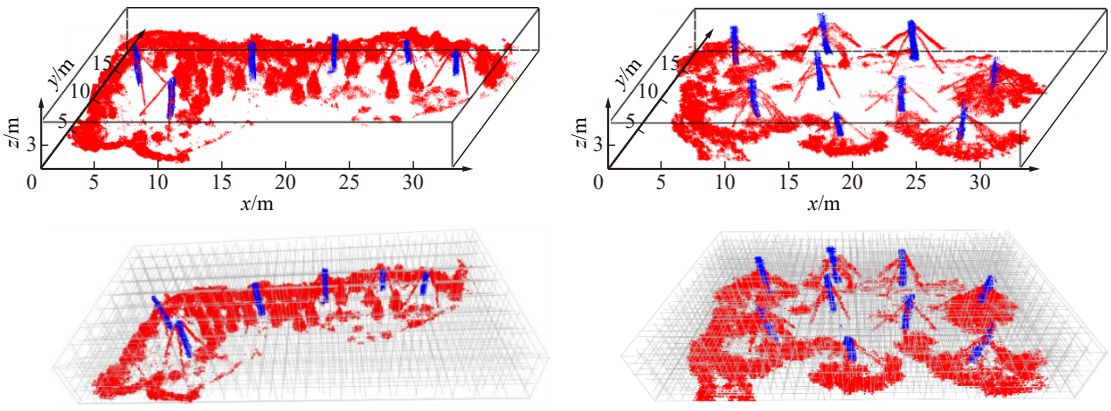


图 2　上海植物园 4 片样地实景图

Fig. 2　Realistic pictures of four sample plots in Shanghai Botanical Garden



红色点表示干扰物，蓝色点表示高大乔木主干。

图 3　数据预处理及体素化示意图

Fig. 3　Schematic diagram of data preprocessing and voxelization

（*Metasequoia glyptostroboides*）、樟树（*Cinnamomum camphora*），以测试 UFNet 在不同区域、不同林型的泛化能力。

2.2 验证方法

2.2.1 数据集构建与验证策略

为系统评估 UFNet 模型在高大乔木林下干扰物滤除任务中的有效性，首先在上海植物园的 4 片典型样地开展实验，4 片样地中共计 342 棵树木。考虑到样地间林下结构差异性较大，为增强实验结果的稳定性与泛化能力，本文采用交叉验证策略进行训练与测试，即每次选取其中 3 片样地作为训练集，剩余 1 片作为测试集，轮流进行 4 轮实验，最终取平均结果作为整体性能评估指标。同时，使用包括 300 棵树的南京林业大学数据集作为辅助数据集，以验证 UFNet 在不同林木场景下的泛化能力。

2.2.2 评价指标

本文采用精度、召回率、F_1 分数、交并比 4 项指标评估模型林下干扰物滤除性能，并补充引入 Boundary IoU（BIoU）[12]与 BF-score[13]两个指标，以进一步评估干扰物与树干交界处的轮廓一致性。针对下游任务的单株分割验证，为量化滤除前后对单株分割的影响，本文统计了真正类（正确分割的单木数量）、假正类（将干扰物误识为单木的数量）、假负类（未被识别出的单木数量），并据此计算单株分割任务的各项精度指标。

2.2.3 实验平台与训练参数

实验在 Ubuntu 18.04 操作系统下运行，计算平台配置为 AMD EPYC 9754 处理器，32 GB 内存，以及 NVIDIA RTX 4090 GPU。稀疏卷积操作基于 Minkowski Engine[14]实现，优化算法采用 Adam 优化器[15]，其中一阶矩估计的指数衰减率 β_1 设为 0.9，二阶矩估计的指数衰减率 β_2 设为 0.999，初始学习率设为 1×10^{-3}，在前 5 个训练轮次执行线性预热以提升至基准学习率，随后使用余弦退火策略[16]进行衰减，设置总训练轮数为 120，余弦衰减周期设为 115，使学习率平滑降至最小学习率 1×10^{-5}，损失函数为二分类交叉熵，体素边长为 2 cm。

2.2.4 对比实验与下游任务验证

在验证环节，本文在两组数据集上将 UFNet 与 5 种主流点云语义分割方法进行了对比，包括 3 种基于点的方法（PointNet++[17]、PointGroup[18]、SCF-Net[19]）与 2 种基于体素的方法（VoxelNet[8]、PCSCNet[20]），通过可视化结果直观呈现滤除性能，并对典型场景进行重点分析对比。此外，为验证滤除算法对下游任务的增益，在上海植物园全部试验样地上使用基于体元逐层聚类的单木分割算法[21]，通过对比滤除前后单株树木分割效果的变化，量化评估 UFNet 对实际林业参数获取任务的支撑作用。

2.2.5 消融实验与参数讨论

为评估各模块贡献，本研究在上海植物园数据集上构建 3 种变体模型与完整模型比较：移除体素特征编码的 Variant-1、移除层次化编码器−解码器的 Variant-2，以及将稀疏卷积改为密集卷积的 Variant-3；除被消融模块外其余设置均一致。

在预处理阶段，本文按垂直高度裁剪出 0 ~ 6 m 的点云子集，为避免该裁剪阈值选择缺乏统计依据，本研究在上海植物园数据集上对不同的点云剪裁高度进行模型性能测试，以探究其是否依赖于特定的人工裁剪边界。

最后，为探究空间分辨率与网络深度对模型性能的影响，实验对不同体素网格边长（1 ~ 5 cm）及 SSC-block 堆叠层数（2 ~ 6 层）进行组合测试，以确定最优性能参数配置。

3 验证结果与分析

3.1 林下干扰物滤除效果

3.1.1 上海植物园数据集

上海植物园 4 片样地的原始点云（图 4a、b、g、h）显示：林下存在大量的干扰物，如支撑物、灌木和低矮植被等。图 4c、d、i、j 为对应区域中模型分割出的干扰物图像，展示了 UFNet 对于林下非树干目标的精确识别与提取效果：大部分干扰物被成功分离出来，保留了较完整的结构信息，验证了模型在复杂背景下的识别能力。图 4e、f、k、l 则展示了在滤除所有干扰物之后，保留下来的树干点云图像。通过 UFNet 的语义预测与过滤机制，图中树干区域的结构更加清晰完整，为后续单株分割与结构参数提取提供了纯净、准确的输入数据。

3.1.2 南京林业大学数据集

南京林业大学样地原始点云（图 5a、b）显示：林下存在大量低矮植被，以及部分树木支撑物，人行道两侧有座椅、道路边界标志物。从图 5e、f 中可以看到，UFNet 能够准确识别并分离干扰物，保留下来的树干结构更加完整清晰。这说明本方法在不同区域、不同林型条件下也能保持较高的分割精度，具有良好的鲁棒性与推广价值。

3.1.3 不同方法的林下干扰物滤除效果对比

在上海植物园数据集上，UFNet 在精度 88.72%、召回率 88.65%、F_1 分数 88.69%、交并比 79.67% 方面均优于其他方法；在南京林业大学数据集上，UFNet 同样保持领先，达到精度 89.82%、召回率 89.65%、F_1 分数 89.73%、交并比 81.38%，体现出更

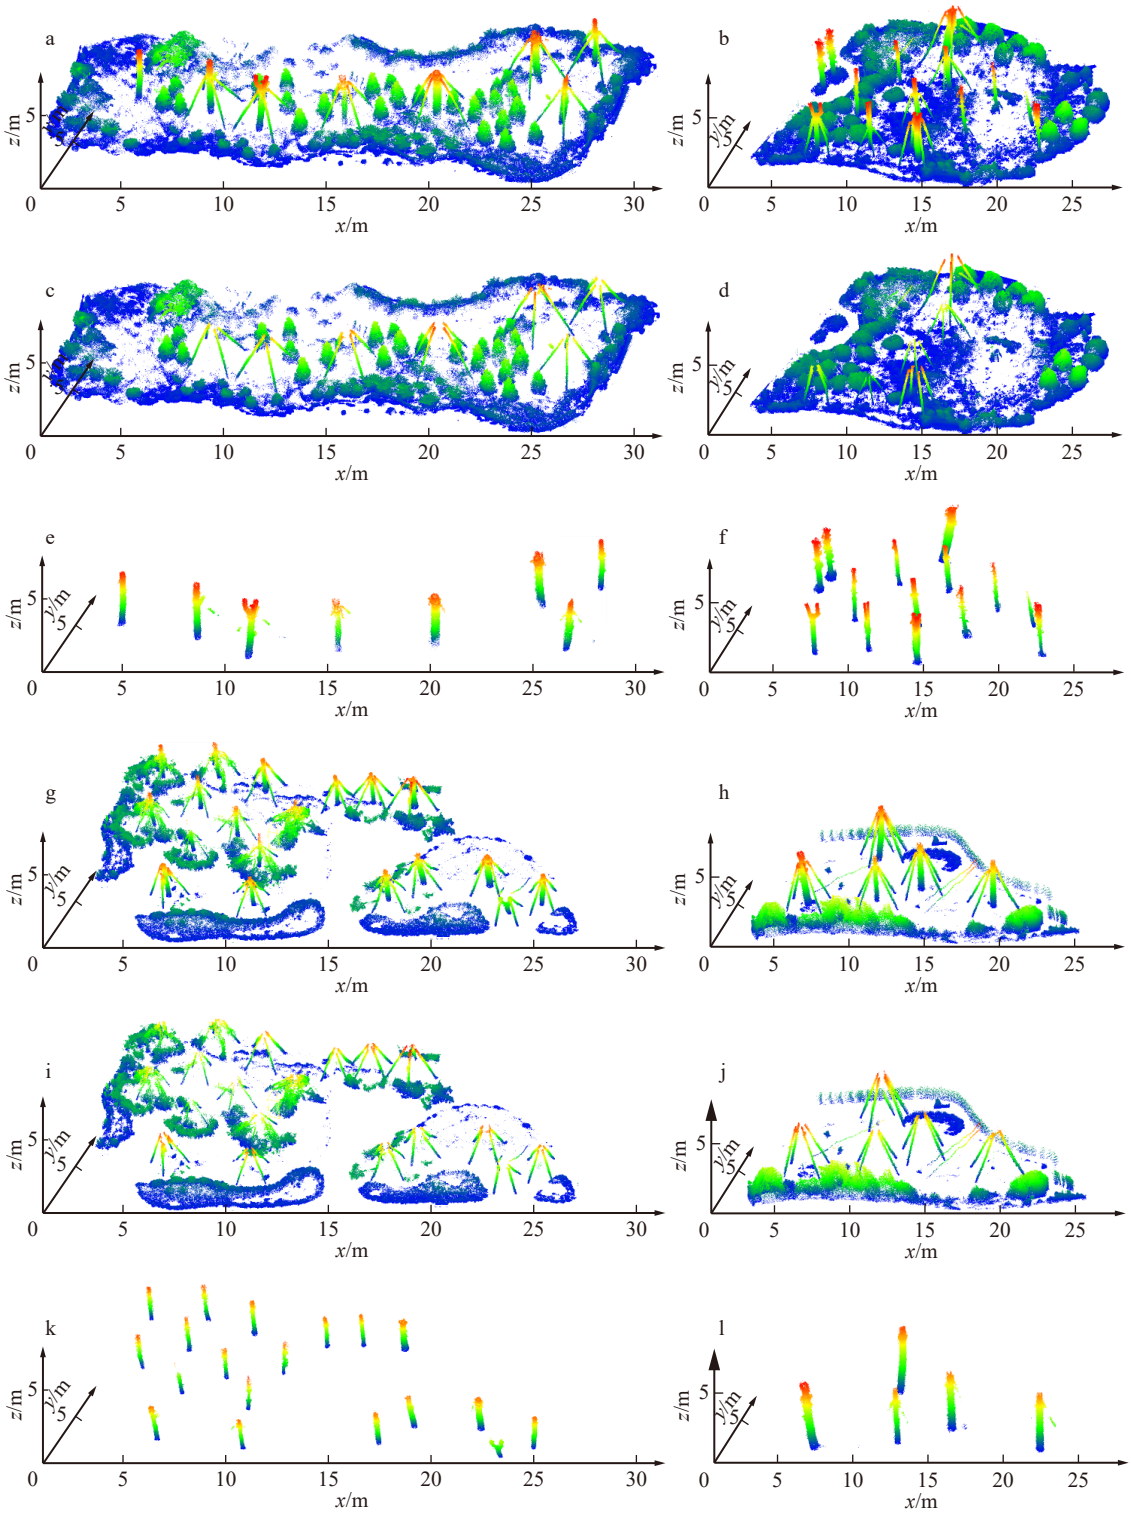


图 4　上海植物园数据集林下干扰物滤除效果可视化图

Fig. 4　Visualization of understory clutter filtering results for the Shanghai Botanical Garden dataset

强的目标判别能力和分割一致性（表 1）。从方法结构来看，尽管近年来部分基于点的方法取得了一定进展，但整体性能仍不及最新的基于体素的方法，后者通过空间离散化与特征聚合，实现了更强的结构建模能力。

UFNet 在两组数据集上的边界一致性均显著领先（表 2）。在上海植物园数据集上，UFNet 的 BIoU 76.23%、BF-score 87.06%，较次优的 PCSCNet 分别高了 7.44、5.94 个百分点；在南京林业大学数据集上，UFNet 的 BIoU 79.24%、BF-score 89.17%，相对 PCSCNet 亦分别提升了 7.42、5.24 个百分点。说明 UFNet 的优势不仅体现在整体掩膜精度，也体现在轮廓对齐与边界连续性上。

图 6 展示了 PCSCNet 与 UFNet 在部分典型场

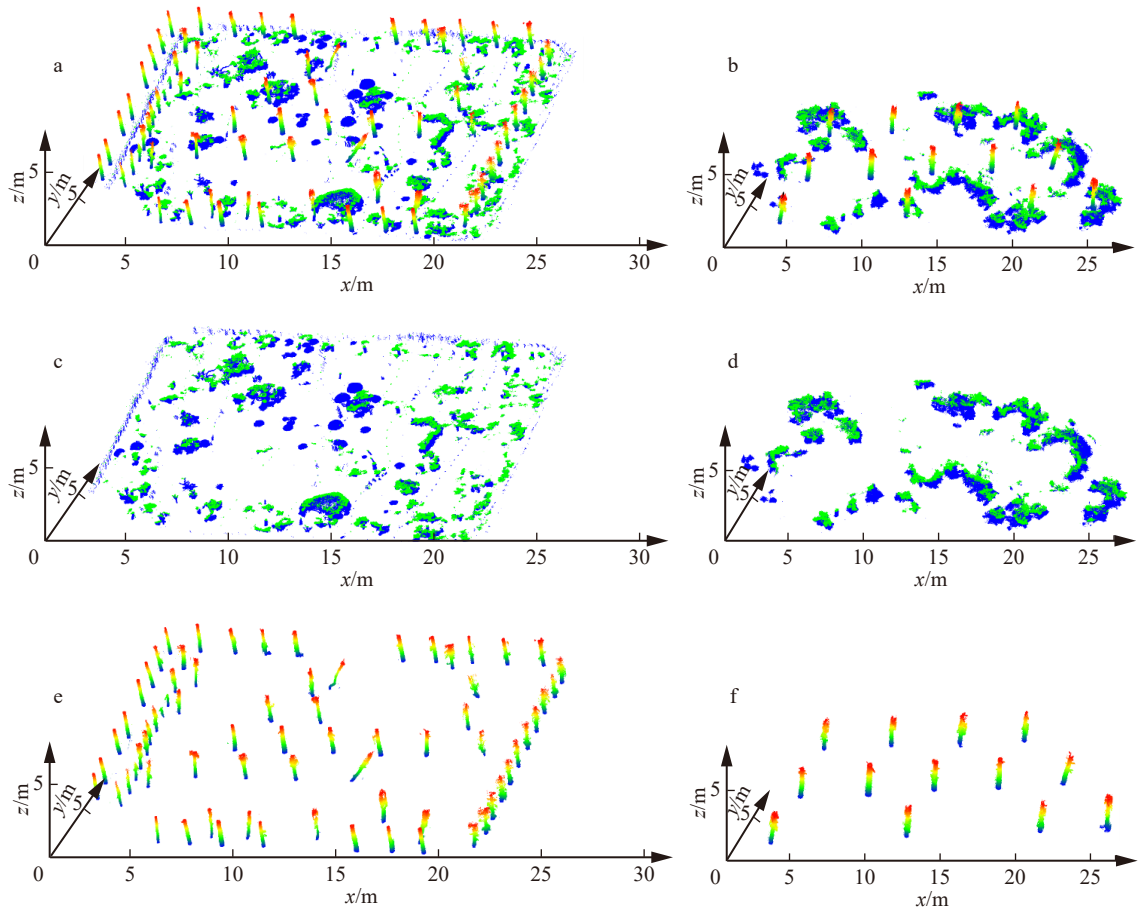


图 5 南京林业大学数据集林下干扰物滤除效果可视化图

Fig. 5 Visualization of understory clutter filtering results for the Nanjing Forestry University dataset

表 1 测试样地中不同方法的比较

Tab. 1 Comparison of different methods in test plots %

方法	上海植物园数据集				南京林业大学数据集			
	精度	召回率	F_1分数	交并比	精度	召回率	F_1分数	交并比
Pointnet++	78.51	77.28	77.89	63.79	80.51	79.28	79.89	66.51
PointGroup	80.32	79.45	79.88	66.53	82.12	81.15	81.63	68.96
SCF-Net	83.69	82.12	82.91	70.79	84.07	83.04	83.55	71.75
Voxelnet	82.47	81.54	82.01	69.49	85.19	83.72	84.45	73.08
PCSCNet	85.24	83.61	84.42	73.04	86.44	84.91	85.67	74.93
UFNet	88.72	88.65	88.69	79.67	89.82	89.65	89.73	81.38

表 2 不同方法的分割边界准确性比较

Tab. 2 Comparison of segmentation boundary accuracy using different methods %

方法	上海植物园数据集		南京林业大学数据集	
	BIoU	BF-score	BIoU	BF-score
Pointnet++	58.93	73.41	61.86	76.18
PointGroup	61.17	75.26	64.37	77.68
SCF-Net	66.07	79.43	67.12	80.57
Voxelnet	64.38	78.46	69.04	82.07
PCSCNet	68.79	81.12	71.82	83.93
UFNet	76.23	87.06	79.24	89.17

景下的语义分割效果局部放大图，在该典型场景中，树干的倾斜程度与人工支撑物的高度一致，属于本任务中最难识别的分割情形。PCSCNet 采用局部插值卷积，依赖有限邻域点的权重拟合，对边界点和稀疏区域较为敏感，其次是 PCSCNet 在点级卷积后再进入稀疏卷积主干，其计算路径对活跃体素的约束不如纯子流形稀疏链路严格。因此，在树干–干扰物交界处，当点分布不均时，插值稳定性下降，易产生误判。PCSCNet 的分割效果（图 6a、c），以及对应场景下 UFNet 的分割效果（图 6b、d）显示：PCSCNet 在分割过程中存在较多误判现象，例如将部分树干区域错误标记为干扰物（红色），以及将支撑物、灌木等干扰物误识别为树干（蓝色），导致整体分割精度降低。而 UFNet 通过 VFE 强化体素的局部集合表征，随后结合层次化编码器–解码器与子流形稀疏卷积在高分辨率下进行多尺度融合与边界细化，因而在同一场景下的分割效果更为精确，能够较好地区分树干与干扰物，虽然在少数区域仍存在误差，但整体分割结果更加清晰，结构完整性更高，显著优于 PCSCNet。

3.2　林下干扰物滤除对单株树木分割精度的影响

图 7 展示了部分典型区域在滤除前后的单株分割效果对比。图 7a、c 为原始点云数据上的单株分割结果图，未进行干扰物去除处理，图 7b、d 为对应区域在滤除干扰物后的单株分割结果图。通过对比可以观察到，在原始数据图中，由于林下存在支撑物、灌木等干扰物的干扰，部分树木在分割过程中被误判为多个独立个体（多棵树），表现为同一棵树被赋予了多种颜色，树干连贯性差，冠层边界模糊。而在去除干扰物之后，单株分割的效果显著提升，每一棵树的边界更加清晰，结构更为完整，颜色分配准确，显著减少了过分割现象。该实验结果充分说明了本文提出的干扰物滤除方法对于提高单株树木分割精度的有效性。

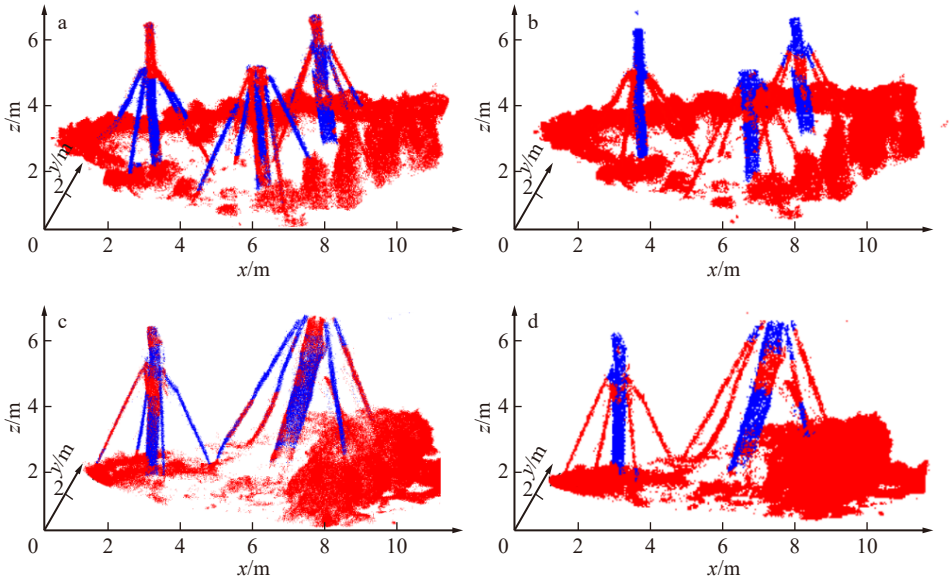


图 6　PCSCNet 和 UFNet 在部分典型区域的分割效果局部放大对比图

Fig. 6　A local enlarged comparison of the segmentation effects of PCSCNet and UFNet in some typical areas

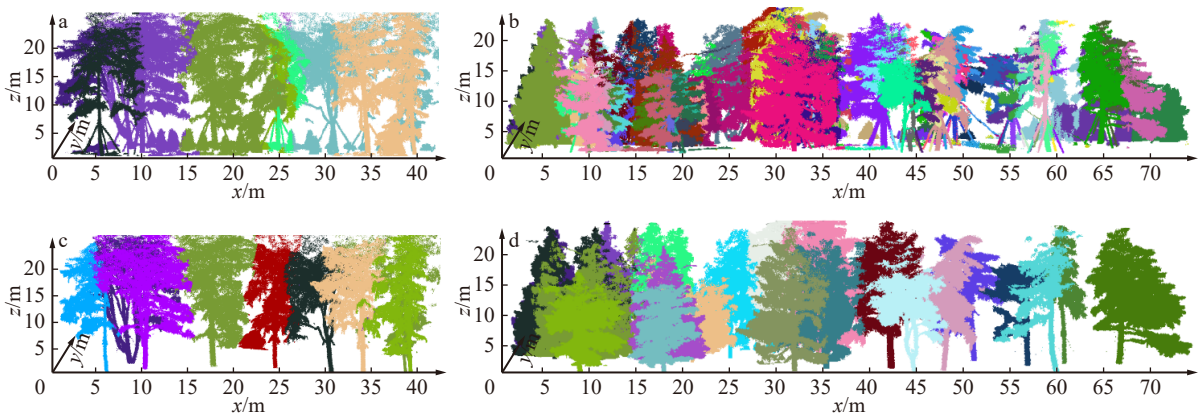


图 7　滤除干扰物前后单株分割效果可视化对比

Fig. 7　Comparison of individual plant segmentation effects before and after filtering out interfering substances

表 3 汇总了在上海植物园全部实验样地上的单株分割对比结果。我们验证了标准预处理的必要性，若去除该步骤而直接分割，性能会显著下降，这说明地形起伏与高度基准不一致会放大实例轮廓误差。在未进行滤除处理的原始点云上，由于存在支撑物、灌木等干扰物，导致精度和召回率较低，F_1 分数和交并比分别仅为 82.68% 和 70.48%。而在经过 6 种滤除方法处理后，分割精度均有不同程度提升。其中，UFNet 的表现最为突出，F_1 分数上升至 94.64%，交并比提升至 89.83%。真正类数量的增加和假正类、假负类数量的减少也进一步印证了分割结果的改进。整体来看，干扰物滤除在优化单株分割边界、提升目标识别完整性方面发挥了关键作用。

3.3 消融实验与参数讨论

3.3.1 消融实验

不使用稀疏卷积对模型性能影响最大，其精度为 79.61%，推理时间延至 9.21 s；不使用 VFE 模块几乎不节省时间，而且导致精度显著下降；不使用层次化编码器–解码器结构使得推理时间轻微减少，但是精度明显下降（表 4）。因此，UFNet 的优势来自 VFE 的体素内交互、SSC 的稀疏性管理以及层次化编码器–解码器的跨尺度聚合的协同作用。

3.3.2 裁剪高度敏感性

在 4 ~ 8 m 区间内，模型的精度、召回率、F_1 分数、交并比几乎不变（表 5），这说明高度上限对精度的影响可忽略。原因在于研究关注的林下干扰物主要分布于 0 ~ 4 m，而林木上部形态对该任务贡献有限。综上，6 m 并非调参得到的特殊阈值，而是基于任务场景的工程化默认值，便于复现实操，且不会限制方法在不同环境下的泛化能力。

3.3.3 性能参数讨论

当体素边长为 2 cm，SSC-block 堆叠 3 层时，模型精度最高（图 8）。当体素边长设置得过小（如 1 cm），网络可能过度关注局部噪声或不相关细节；而当体

表 3 上海植物园全部实验样地上的单株分割对比结果

Tab. 3 Comparison of individual tree segmentation results across all experimental plots in Shanghai Botanical Garden

处理	方法	真正类	假正类	假负类	精度/%	召回率/%	F_1分数/%	交并比/%
未预处理		232	52	110	81.69	67.84	74.12	62.13
未滤除		265	34	77	88.64	77.52	82.68	70.48
滤除后	Pointnet++	275	30	67	90.16	80.41	85.01	72.39
	PointGroup	283	24	59	92.17	82.75	87.17	74.91
	SCF-Net	295	22	47	93.06	86.26	89.52	78.85
	Voxelnet	286	30	56	90.51	83.63	86.93	76.31
	PCSCNet	301	17	41	94.66	88.01	91.22	82.44
	UFNet	318	12	24	96.36	93.03	94.64	89.83

表 4 消融实验

Tab. 4 Ablation experiment

模型	体素特征编码	稀疏卷积	层次化编码器–解码器	精度/%	推理时间/s
Variant-1	×	√	√	83.59	5.37
Variant-2	√	√	×	82.13	4.93
Variant-3	√	×	√	79.61	9.21
UFNet	√	√	√	88.72	5.42

表 5 裁剪高度的敏感性分析

Tab. 5 Trimmed data sensitivity analysis %

裁剪高度/m	精度	召回率	F_1分数	交并比
4	88.63	88.66	88.64	79.55
5	88.70	88.62	88.66	79.62
6	88.72	88.65	88.69	79.67
7	88.66	88.69	88.68	79.61
8	88.57	88.60	88.58	79.50

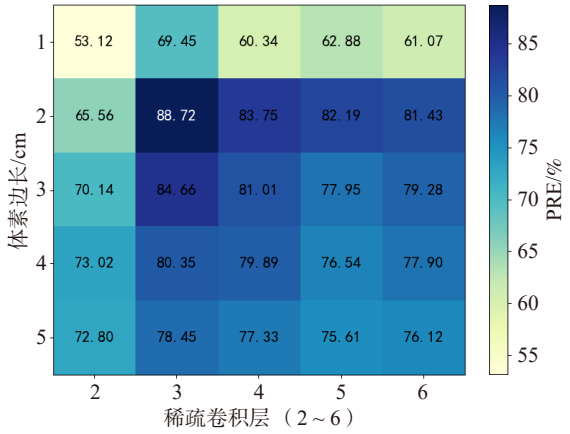


图 8　体素网格大小与 SSC-block 堆叠层数对模型性能的影响

Fig. 8　Effects of voxel grid size and number of SSC-block stacking layers on model performance

素边长过大（如 5 cm），则容易造成目标边界模糊与几何细节丢失，影响精度表现。同时，SSC-block 的堆叠层数对模型性能亦有显著影响。适度增加网络深度有助于扩大感受野与提升语义建模能力，但层数过多可能引入冗余计算或导致过拟合风险。综合分析不同参数配置的实验结果可知，选择体素边长为 2 cm，SSC-block 为 3 层能够在网络深度与空间分辨率之间取得较优平衡，为后续任务提供稳定可靠的语义表示。

4　结　　论

本文针对城市景观森林中高大乔木林下区域干扰物结构复杂，传统方法难以准确滤除的问题，提出了一种基于深度学习的林下干扰物智能滤除方法 UFNet。该方法融合了体素特征编码与子流形稀疏卷积模块，在保持稀疏性的同时增强了局部几何结构建模能力。同时引入层次化编码器–解码器结构，实现了多尺度特征提取与上下文信息融合，有助于提升干扰物滤除效果。

使用上海植物园 4 片样地的点云数据对 UFNet 进行验证，通过交叉验证与多方法对比评估，相较于 5 种主流方法，UFNet 在精度、召回率、F_1 分数与交并比等指标上分别提升了 3.48 ~ 10.21、5.04 ~ 11.37、4.27 ~ 10.80、6.63 ~ 15.88 个百分点，为后续的单株树木分割提供了纯净、准确的输入数据。

但是在城市景观森林中，还存在部分高度不高的乔木幼树，它们不同于灌木或草本植被，在结构识别上具有一定特殊性。如何在滤除干扰物的同时精细地区分此类幼树与灌木杂草，是未来研究需要进一步关注的问题。

参　考　文　献

[1] Zhang B, Li X, Du H, et al. Estimation of urban forest characteristic parameters using UAV-lidar coupled with canopy volume [J]. Remote Sensing, 2022, 14(24): 6375.

[2] Zhang J, Wang J, Liu G. Vertical structure classification of a forest sample plot based on point cloud data [J]. Journal of the Indian Society of Remote Sensing, 2020, 48(8): 1215−1222.

[3] 张建鹏, 王金亮, 刘广杰, 等. 基于地基雷达点云主方向的林下植被自动滤除 [J]. 遥感技术与应用, 2023, 38(2): 405−412.
Zhang J P, Wang J L, Liu G J, et al. Automatic filtering of understory vegetation based on point cloud main direction of terrestrial laser scanning [J]. Remote Sensing Technology and Application, 2023, 38(2): 405−412.

[4] 聂辰辰, 程峰, 王成, 等. 地面激光雷达点云数据乔灌分离方法研究 [J]. 测绘科学, 2024, 49(1): 106−116.
Nie C C, Cheng F, Wang C, et al. Terrestrial laser scanning point cloud data tree-shrub separation method research [J]. Science of Surveying and Mapping, 2024, 49(1): 106−116.

[5] Henrich J, van Delden J, Seidel D, et al. TreeLearn: a deep learning method for segmenting individual trees from ground-based LiDAR forest point clouds [J]. Ecological Informatics, 2024, 84: 102888.

[6] Xia K, Li C, Yang Y, et al. Study on single-tree extraction method for complex RGB point cloud scenes [J]. Remote Sensing, 2023, 15(10): 2644.

[7] Kim D H, Ko C U, Kim D G, et al. Automated segmentation of individual tree structures using deep learning over LiDAR point cloud data [J]. Forests, 2023, 14(6): 1159.

[8] Zhou Y, Tuzel O. VoxelNet: End-to-end learning for point cloud based 3D object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City. IEEE, 2018: 4490−4499.

[9] Graham B, Engelcke M, van der Maaten L. 3D semantic segmentation with submanifold sparse convolutional networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City. IEEE, 2018: 9224−9232.

[10] Zhang G, Junnan C, Gao G, et al. Hednet: A hierarchical encoder-decoder network for 3d object detection in point clouds [J]. Advances in Neural Information Processing Systems, 2023, 36: 53076−89.

[11] Liu K, Wang W, Tharmarasa R, et al. Ground surface filtering of 3D point clouds based on hybrid regression technique [J]. IEEE Access, 2019, 7: 23270−23284.

[12] Cheng B, Girshick R, Dollar P, et al. Boundary IoU: improving object-centric image segmentation evaluation[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville. IEEE, 2021: 15329−15337.

[13] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//Proceedings Eighth IEEE International Conference

on Computer Vision. ICCV 2001. Vancouver. IEEE, 2001: 416−423.

[14] Choy C, Gwak J, Savarese S. 4D spatio-temporal ConvNets: Minkowski convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach. IEEE, 2019: 3070−3079.

[15] Kingma D P, Ba J. Adam: a method for stochastic optimization [C]//International Conference on Learning Representations (ICLR). San Diego: ICLR. 2015.

[16] Ilya L, Frank H. SGDR: stochastic gradient descent with warm restarts [C]//International Conference on Learning Representations (ICLR). Toulon: ICLR. 2017.

[17] Qi C R, Yi L, Su H, et al. Pointnet++: deep hierarchical feature learning on point sets in a metric space [C]//Advances in Neural Information Processing Systems (NeurIPS). Long Beach: NeurIPS. 2017.

[18] Jiang L, Zhao H, Shi S, et al. PointGroup: dual-set point grouping for 3D instance segmentation[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 4866−4875.

[19] Fan S, Dong Q, Zhu F, et al. SCF-net: Learning spatial contextual features for large-scale point cloud segmentation[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 14499−14508.

[20] Park J, Kim C, Kim S, et al. PCSCNet: Fast 3D semantic segmentation of LiDAR point cloud for autonomous car using point convolution and sparse convolution network [J]. Expert Systems with Applications, 2023, 212: 118815.

[21] 邢万里, 邢艳秋, 黄杨, 等. 基于体元逐层聚类的 TLS 点云数据单木分割算法 [J]. 中南林业科技大学学报, 2017, 37(12): 58−64,71.

Xing W L, Xing Y Q, Huang Y, et al. Individual tree segmentation of TLS point cloud data based on clustering of voxels layer by layer [J]. Journal of Central South University of Forestry & Technology, 2017, 37(12): 58−64,71.

（责任编辑 吴 娟
责任编委 李文彬）