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

改进PointNet++语义分割与三维重建融合的绿篱修剪智能决策框架

马润辰 马跃威 安健硕 李文彬 徐道春 白效鹏

A framework integrating improved PointNet++ segmentation and 3D reconstruction towards intelligent hedge trimming decisions

Ma Runchen, Ma Yuewei, An Jianshuo, Li Wenbin, Xu Daochun, Bai Xiaopeng

引用本文:
马润辰, 马跃威, 安健硕, 李文彬, 徐道春, 白效鹏. 改进PointNet++语义分割与三维重建融合的绿篱修剪智能决策框架[J]. 北京林业大学学报, 2026, 48(5):157–168. doi: 10.12171/j.1000–1522.20260067
Ma Runchen, Ma Yuewei, An Jianshuo, Li Wenbin, Xu Daochun, Bai Xiaopeng. A framework integrating improved PointNet++ segmentation and 3D reconstruction towards intelligent hedge trimming decisions[J]. Journal of Beijing Forestry University, 2026, 48(5):157–168. doi: 10.12171/j.1000–1522.20260067

在线阅读 View online: https://doi.org/10.12171/j.1000–1522.20260067

您可能感兴趣的其他文章

Articles you may be interested in

路侧绿篱修剪机器人的设计与试验评估
Design and experimental evaluation of a roadside hedge trimming robot
北京林业大学学报, 2025, 47(5): 1–13. https://doi.org/10.12171/j.1000–1522.20250029

基于语义分割和融合算法的草坪杂草定位
Lawn weed localization based on semantic segmentation and fusion algorithms
北京林业大学学报, 2024, 46(7): 133–138. https://doi.org/10.12171/j.1000–1522.20240057

数字孪生驱动森林精准经营决策：理论模型、关键技术与应用示范
Digital–twin–driven precise forest management and decision–making: theoretical models, key technologies and application demonstrations
北京林业大学学报, 2025, 47(11): 1–16. https://doi.org/10.12171/j.1000–1522.20250340

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

基于改进CenterNet的无人机森林病虫害图像目标检测方法
UAV–based forest pest image object detection using improved CenterNet
北京林业大学学报, 2026, 48(3): 140–151. https://doi.org/10.12171/j.1000–1522.20240018

DOI:10.12171/j.1000−1522.20260067

改进 PointNet++语义分割与三维重建融合的绿篱修剪智能决策框架

马润辰　马跃威　安健硕　李文彬　徐道春　白效鹏
（北京林业大学工学院，北京 100083）

摘要:【目的】针对现有绿篱自动修剪方法中目标修剪轮廓依赖人工预设轮廓、无法根据生长状态自主决策的根本性局限，本研究旨在提出一种可自主完成“感知—理解—决策”的智能化修剪点生成框架，以推动修剪作业从程序化自动向智能自主跨越。**【方法】**本研究提出“智能分割—几何拟合—任务生成”三层级技术框架。首先，通过神经辐射场（NeRF）从环绕拍摄视频重建高保真度的绿篱点云。进而，改进 PointNet++，构建 Hedge-PointNet，引入 Softmax 点级概率建模与多轮推理融合策略，实现绿篱与背景的精准语义分割。随后，依据语义类别自适应选择随机抽样一致性算法（RANSAC）等鲁棒的几何拟合方法，三维重建目标修剪曲面。最后，通过曲面网格化与投影策略，智能化提取实际修剪点。**【结果】**在复杂真实场景下的实验结果表明：（1）所提 Hedge-PointNet 的语义分割平均交并比（mIoU）达 0.971，显著优于基线模型；（2）在球面拟合任务中，RANSAC 算法的均方根误差为 0.005 1 m，较传统最小二乘法降低了 96.7%，对离群点表现出优异鲁棒性；（3）该方法生成的修剪点集仅需覆盖目标曲面 36.1% 的潜在点位，即可实现同等修剪效果，无效修剪动作减少 63.9%，在精度与效率间取得最佳平衡。**【结论】**本研究不仅实现了绿篱修剪轮廓的自主判断与作业指令的智能生成，还可作为自动化修剪装备中的感知与决策模块，为后续路径规划与机械执行提供目标参数与作业点位输入。该框架具有良好的通用性，可为园林养护、农作物整形修剪及相关机器人三维作业任务中的目标识别与作业决策提供参考。

关键词：PointNet++；语义分割；三维重建；点云处理；深度学习；智能决策；绿篱修剪；农业机器人
中图分类号：TP242.6；TP391.41　　**文献标志码：**A　　**文章编号：**1000−1522(2026)05−0157−12
引文格式：马润辰，马跃威，安健硕，等. 改进 PointNet++语义分割与三维重建融合的绿篱修剪智能决策框架［J］. 北京林业大学学报，2026，48(5)：157−168. Ma Runchen, Ma Yuewei, An Jianshuo, et al. A framework integrating improved PointNet++ segmentation and 3D reconstruction towards intelligent hedge trimming decisions［J］. Journal of Beijing Forestry University, 2026, 48(5): 157−168.

A framework integrating improved PointNet++ segmentation and 3D reconstruction towards intelligent hedge trimming decisions

Ma Runchen　Ma Yuewei　An Jianshuo　Li Wenbin　Xu Daochun　Bai Xiaopeng
(School of Technology, Beijing Forestry University, Beijing 100083, China)

Abstract: ［**Objective**］ Existing automatic hedge-trimming methods fundamentally rely on manually predefined target contours and are unable to make autonomous decisions according to actual growth conditions. To address this limitation, this study aims to propose an intelligent trimming-point generation framework capable of autonomously completing the processes of “perception-understanding-decision-making”, thereby promoting hedge trimming from programmed automation to intelligent autonomy. ［**Method**］ A three-level technical framework of “intelligent segmentation-geometric fitting-task generation”

收稿日期: 2026−02−05　**修回日期:** 2026−03−25
基金项目: 国家重点研发计划课题（2018YFD0700601）。
第一作者: 马润辰。主要研究方向：林业机器人、点云处理。Email：mrc3230274@bjfu.edu.cn　地址：100083 北京市海淀区清华东路 35 号北京林业大学工学院。
责任作者: 李文彬，教授，博士生导师。主要研究方向：林业工程装备自动化及人机环境工程。Email：leewb@bjfu.edu.cn　地址：同上。
本刊网址: https://j.bjfu.edu.cn；https://journal.bjfu.edu.cn

was proposed. First, high-fidelity hedge point clouds were reconstructed from surround-view videos using neural radiance fields (NeRF). Then, PointNet++ was innovatively improved to build Hedge-PointNet, in which point-wise Softmax probability modeling and multi-round inference fusion strategies were introduced to achieve accurate semantic segmentation of hedges and background. Subsequently, robust geometric fitting methods, including random sample consensus (RANSAC), were adaptively selected according to semantic categories to reconstruct the target trimming surface. Finally, actual trimming points were intelligently extracted through surface meshing and point-cloud projection strategies. [**Result**] Experimental results in complex real-world scenes showed that: (1) the proposed Hedge-PointNet achieved a mean intersection over union (mIoU) of 0.971 in semantic segmentation, significantly outperforming the baseline model; (2) in the spherical fitting task, the root mean square error of the RANSAC algorithm was 0.005 1 m, which was 96.7% lower than that of the conventional least-squares method, demonstrating strong robustness to outliers; (3) the generated trimming-point set only needed to cover 36.1% of the potential points on the target surface to achieve the same trimming effect, reducing ineffective trimming actions by 63.9% and achieving a favorable balance between accuracy and efficiency. [**Conclusion**] This study not only realized autonomous determination of hedge trimming contours and intelligent generation of operation instructions but also can serve as a perception and decision-making module in automated trimming equipment, providing target parameters and operation-point inputs for subsequent path planning and mechanical execution. The proposed framework shows good generality and can provide a reference for target recognition and operation decision-making in garden maintenance, crop training and pruning, and related robotic 3D operation tasks.

Key words: PointNet++; semantic segmentation; 3D reconstruction; point cloud processing; deep learning; intelligent decision-making; hedge trimming; agricultural robotics

绿篱作为园林景观中常见且具有显著形态特征的植物造景形式，其修剪质量直接影响景观空间的整体美观性与秩序感，同时关系到园林绿地生态功能的稳定发挥[1−2]。科学、合理的绿篱修剪不仅能够维持既定造型，还能够促进植物健康生长，因此绿篱修剪是园林绿化养护作业中的重要组成部分[3]。目前，园林绿篱修剪作业仍主要依赖人工完成，修剪效果在很大程度上取决于作业人员的经验水平，不仅劳动强度大、作业效率低，而且在大尺度作业条件下难以保证整体修剪轮廓的一致性[2−4]。随着城市园林规模的不断扩大，传统人工修剪方式在作业效率、质量稳定性及成本控制等方面的不足日益显现，亟需向机械化和自动化方向发展[3−5]。因此，实现对绿篱修剪轮廓的精准感知与自主判别，是推动绿篱修剪由人工经验型向智能决策型转变的核心前提。

围绕绿篱及灌木修剪的机械化与自动化问题，研究人员在修剪装备结构设计与作业方式方面开展了大量研究。阚延鹏等针对回转型绿篱修剪机建立动力学模型，并通过虚拟样机仿真分析其运动特性，为修剪装备的结构优化提供了理论依据[1]。van Henten 等[6]验证了机器人系统在修剪与采收任务中的可行性，罗海风等[7]搭建了由六自由度机械臂、往复式刀具和履带式底盘组成的修剪机器人，实现了直线、梯形和圆弧 3 种修剪路径，为后续研究奠定了基础。上述研究主要解决了“如何修剪”的装备实现与运动控制问题，但对“修剪到何种形态”的目标判定依赖预设路径或人工设定参数，尚未形成面向目标轮廓自主识别的技术体系。

实现自动化修剪的前提是对修剪对象进行准确感知与定位。部分研究采用二维视觉方法对绿篱或植物目标进行检测与识别，例如王克涛等[8]提出的园林球形绿篱检测方法，以及张佳承等[9]提出的改进型轻量化检测算法，在园林作业场景中取得了一定应用效果。此外，Botterill 等[10]通过视觉信息实现树木修剪作业，验证了视觉感知在自动修剪中的可行性。然而，这类方法主要基于二维图像特征进行目标识别，其输出结果通常局限于目标检测或轮廓分割层面，难以准确表达绿篱的三维空间结构信息。因此，二维视觉方法在描述植物空间结构方面仍存在一定局限，难以满足精细化修剪需求。

为获取更完整的空间结构信息，部分研究引入三维感知与建模技术，对植物或绿篱进行三维重建，并据此开展修剪作业。Gu 等[11]通过绿篱三维重建获取其空间形态，并结合运动控制方法实现修剪操作；Sampaio 等将三维感知与几何分析相结合，用于机器人修剪任务中的作业决策[12]；Tabb 等[13]利用三维重建技术辅助植物修剪，提高了修剪精度。相关研究表明，三维空间信息在修剪点判定和修剪路径规

划中具有重要作用[14]。尽管三维重建为修剪对象提供了更为完整的空间表达，但多数研究仍停留在几何形态重建与路径生成层面，对三维数据中隐含的语义信息利用不足。

在修剪点提取方面，现有研究多基于几何建模思想，通过构建理想修剪模型或目标曲面来判别待修剪区域[11−12, 15]。这类方法在规则或近似规则植物修剪中具有一定实用性，但通常依赖人工设定目标模型，难以适应复杂或非标准绿篱形态[16]。同时，修剪目标轮廓的确定仍较多依赖经验规则，缺乏对绿篱实际生长状态的综合判别能力。

综上所述，现有研究采用不同方法在绿篱机械化修剪装备设计、路径规划及目标识别等方面取得了一定进展，实现了绿篱的机械化修剪与智能感知。但整体来看，研究重心仍集中于装备实现与作业执行层面，对“原始目标形态的自主推断”这一核心问题关注不足。在实际生长过程中，由于各生长点生长速率和生长量存在差异，绿篱在修剪后一段时间内其外部轮廓会逐渐偏离原始形态。人工修剪时，作业人员可以依据经验辨识绿篱原有的理想形状，并据此进行调整，但现有自动化方法多依赖于人工预设的修剪轮廓，缺乏从三维点云数据中自动识别植物原始生长形态，并判别修剪目标形状的自主推断能力。因此，如何基于三维空间数据，融合几何特征与语义信息，构建能够自主识别绿篱原始轮廓并完成修剪点智能判别的算法模型，成为实现绿篱智能化修剪亟需解决的问题。

因此，针对上述目标轮廓自主判别能力不足的问题，本研究拟探索一种融合三维重建与点云语义理解的绿篱修剪点智能提取框架。具体而言，计划在 PointNet++结构基础上进行针对性改进，构建适用于绿篱修剪场景分割的语义分割网络，以实现对绿篱空间结构与目标形态类别的精细识别。在此基础上，拟结合 RANSAC 对判别得到的目标修剪表面进行稳健拟合，并通过三角网格重构与空间投影方法，实现对偏离目标轮廓区域的精准定位与修剪点判别。通过上述技术路径的整合与验证，本研究旨在实现对绿篱原始目标轮廓的自主推断与动态修剪决策，从而提升修剪作业的智能化水平与稳定性。整体而言，本研究拟探索的方法主要面向自动化修剪系统中的目标识别与决策环节，不仅可服务于绿篱自动修剪任务，还可为复杂三维场景中的目标结构识别与几何约束处理提供方法参考。

1　绿篱点云智能修剪技术框架的构建

为实现绿篱自动化修剪过程中点云数据的高效理解与处理，本文构建一种面向绿篱修剪任务的点云“智能分割—几何拟合—任务生成”技术框架。该框架以三维点云为输入，依次经过语义分割、几何建模、曲面拟合以及修剪点提取等步骤，以实现从原始场景点云到作业点位生成的逐级解析与信息转换。其中，语义分割用于完成绿篱目标及其形态类别的识别，几何建模与曲面拟合用于确定目标修剪表面的参数表达，修剪点提取则进一步将目标轮廓信息转化为可供后续作业调用的空间点位。因而，本文研究内容主要对应自动化修剪系统中的前端感知与决策环节，可为后续轨迹规划与机械执行提供目标表面参数和作业点位输入。

1.1　基于 Hedge-PointNet 的修剪场景语义分割

为了实现修剪表面的精确拟合，首先需要对包含绿篱、背景等目标的三维点云进行高精度语义分割。考虑到绿篱表面点云通常具有曲面连续、局部形态变化复杂、点云密度不均以及与背景几何差异细微等特点，本研究选用具备分层多尺度特征学习能力的 PointNet++作为基础架构[17]。该网络在 PointNet 的基础上[18]，通过递归采样与分组，在不同尺度上聚合局部区域特征，从而能够有效表征绿篱的空间结构。然而，复杂园林环境中的噪声与遮挡易导致原始 PointNet++在分割精度和边界确定性上存在不足，难以直接满足后续几何建模对分割结果鲁棒性的高要求。

为解决上述问题，实现从场景理解到作业决策的精准信息提取，本研究面向绿篱修剪这一具体任务，对 PointNet++的推理与决策机制进行了针对性优化，提出了 Hedge-PointNet。核心改进在于：在推理阶段，引入自适应采样策略，并结合多次推理结果的 Softmax 点级概率输出，通过概率累积融合机制生成最终分割结果。该设计增强了网络对点云局部密度变化和噪声的鲁棒性，提升了模型在复杂真实场景下的泛化能力与分割稳定性，为后续区分不同修剪类型（如球形、方形）并进行精确几何拟合奠定了可靠基础。

Hedge-PointNet 结构图如图 1 所示。该网络在 PointNet++语义分割框架基础上进行了针对复杂枝干点云场景的结构性优化，整体仍由 Set Abstraction（SA）模块与 Feature Propagation（FP）模块两部分构成，并在特征采样与输出阶段引入了自适应机制以提升点级判别能力。网络输入为$(N, d + c)$，其中 N 表示输入点云的点数，d 表示点的空间坐标维度，c 表示附加属性特征，如颜色信息，F 为特征维度，k 为语义类别数量。SA 模块与 FP 模块之间通过跨层滑移连接进行信息交互，以缓解深层网络中语义信

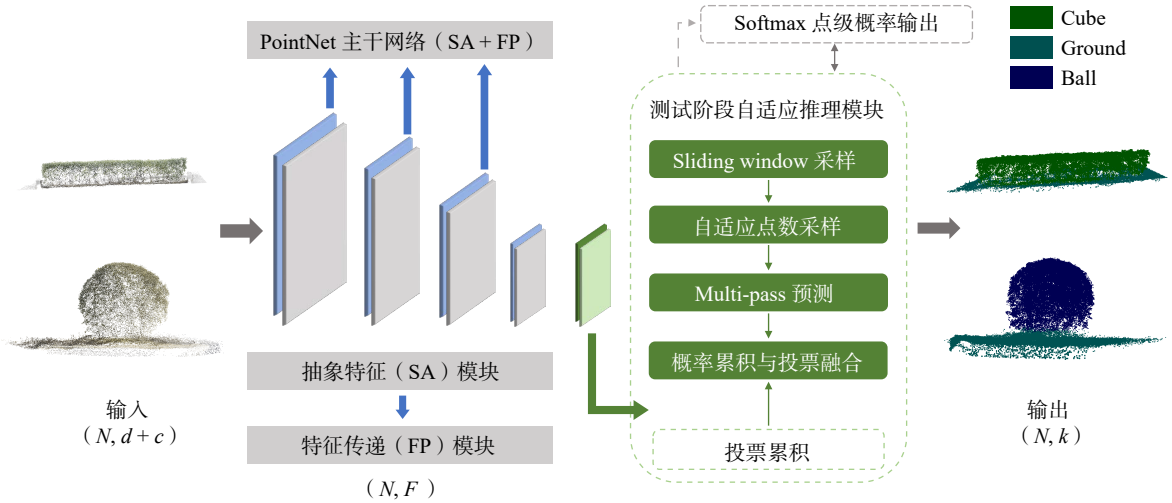


图 1 Hedge-PointNet 结构

Fig. 1 Hedge-PointNet architecture

息丢失的问题。在输出阶段，Hedge-PointNet 采用 Softmax 点级概率输出结构，对每个点的特征向量进行类别概率建模，最终通过最大概率准则获得点云的语义预测结果。该设计使网络不仅能够输出明确的类别标签，同时保留了点级不确定性信息，为后续结构分析与精细化应用提供了可靠依据。

在测试阶段，网络首先对输入点云中的每个点输出类别响应值，并通过 Softmax 函数将其映射为概率分布，其形式定义为

$$P_{i,c}=\frac{\exp(z_{i,c})}{\sum_{k=1}^{C}\exp(z_{i,k})} \tag{1}$$

式中：$P_{i,c}$ 表示第 i 个点属于类别 c 的预测概率，$z_{i,c}$ 为网络输出的对应类别响应值，C 为语义类别总数。该概率分布作为后续多轮推理融合的基础输入。

在整场景推理过程中，Hedge-PointNet 采用滑窗方式对场景进行多次采样，同一空间位置的点在不同采样块中可能被多次预测。为充分利用多视角推理所提供的互补信息，本文在测试阶段引入基于概率累积的多轮融合策略，对同一点在不同推理轮次中的预测结果进行统一建模，其累积形式表示为

$$V_{i,c}=\sum_{v}^{V}P_{i,c}^{v} \tag{2}$$

式中：$V_{i,c}$ 表示点 i 在类别 c 上的累积响应值，V 为测试阶段的预测轮次总数，$P_{i,c}^{v}$ 为第 v 次推理中获得的预测概率。该累积机制能够在一定程度上抑制单次预测中的随机误差，使得预测结果更具稳定性。

在完成多轮预测概率的累积后，最终的点级语义类别由其在所有类别上的累积响应值共同决定，具体判定规则为

$$\hat{y}_i=\arg\max_{c}V_{i,c} \tag{3}$$

通过上述自适应融合策略，Hedge-PointNet 在测试阶段实现了对多次预测结果的有效整合，从而在不引入额外训练参数的情况下，显著增强了网络对复杂空间结构和类别边界区域的判别能力。

与基准模型 PointNet++相比，Hedge-PointNet 的改进主要体现在两个方面：(1)在测试阶段引入基于 Softmax 输出概率的多轮预测融合机制，将点级类别概率作为中间语义表示进行累积建模，从而提升小尺度场景下类别判别的稳定性；(2)结合绿篱场景尺寸特征，对采样策略进行自适应调整，使网络更适用于点云规模相对较小且结构集中的园林场景。通过上述改进，在不显著增加网络参数规模的前提下，提升了网络在复杂绿篱场景中的分割精度与鲁棒性。

1.2 几何参数模型构建

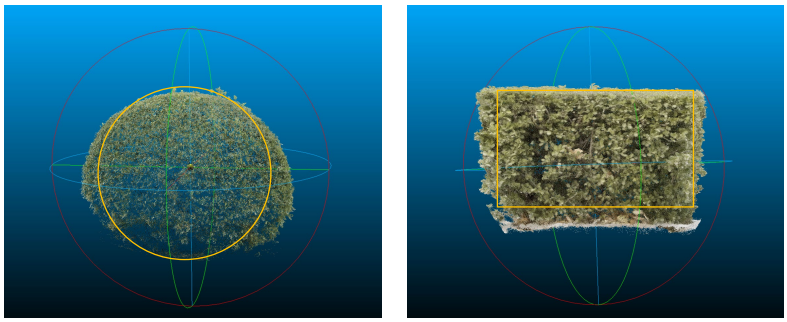
使用 Hedge-PointNet 对含有绿篱点云的场景进行分割，将分割后标签值为 1 的点云导出作为待修剪的球形绿篱，标签值为 2 的点云导出作为待修剪的方形绿篱。

两种绿篱的点云模型如图 2 所示，将中心点坐标均设为(x_0,y_0,z_0)，根据立体几何知识，拟合球面的方程可表达如式(4)。

$$(x-x_0)^2+(y-y_0)^2+(z-z_0)^2=r^2 \tag{4}$$

式中：r 为拟合球面的半径。

设长方体的中心坐标为原点，长宽高分别为 $2a$、$2b$ 和 $2h$，不同于球面可以直接用单一的参数方程表示，立方体需要借助变量范围单独表达各个表面。对于绿篱修剪而言，长方体的下表面属于不用修剪的面，故只需表达除下表面以外的 5 个表面。以长方体中心点为坐标系原点，平行于长宽高的轴建立坐标系 L，则除下表面以外的 5 个表面可表达为式(5)。



a 球形绿篱点云　　b 方形绿篱点云

图 2　不同形状的绿篱点云

Fig. 2　Hedge point clouds with different shapes

$$\begin{cases} x=\pm a,\ y\in(-b,b),\ z\in(-h,h) \\ y=\pm b,\ x\in(-a,a),\ z\in(-h,h) \\ z=h,\ x\in(-a,a),\ y\in(-b,b) \end{cases} \tag{5}$$

式中：x 为平面上点的横坐标，y 为平面上点的纵坐标，z 为平面上点的竖坐标。

考虑到实际拟合过程中长方体可能存在整体姿态偏转，其各棱边方向不一定与全局坐标轴平行，因此通过旋转矩阵对其空间姿态进行描述。引入欧拉角(α, β, γ)描述从长方体局部坐标系 L 到全局坐标系 G 的旋转关系，则相应的旋转矩阵 $\boldsymbol{R}$ 为式(6)。

$$\boldsymbol{R}=\boldsymbol{R}_z(\gamma)\boldsymbol{R}_y(\beta)\boldsymbol{R}_x(\alpha) \tag{6}$$

式中：α 为进动角，β 为章动角，γ 为自转角。

结合该旋转矩阵及全局坐标系 G 原点到长方体中心点的向量 $\boldsymbol{c}$，局部坐标系下任意一点 P_{L} 在全局坐标系中的对应位置可表示为式(7)。

$$P_{\mathrm{G}}=\boldsymbol{R}P_{\mathrm{L}}+\boldsymbol{c} \tag{7}$$

式中：P_{G} 为方形面上的点在全局坐标系下的坐标，P_{L} 为方形面上的点在原坐标系下的坐标。

综合以上推导，求解出拟合立方体的中心坐标、长宽高以及欧拉角，即在全局坐标中表达该立方体表面所有的点。

1.3　修剪表面的几何拟合

确定待修剪表面类型后，需要确定待修剪表面的参数，为后续修剪点提取提供具体的修剪面方程。平面绿篱修剪效率受修剪刀具影响较大，故以下研究将基于球形绿篱讨论。根据不同点云采集手段和球形绿篱点云的特性，可以在不同的场景下使用最小二乘法或 RANSAC 对绿篱点云进行拟合。

1.3.1　基于最小二乘准则的曲面拟合

最小二乘法是一种经典的参数估计方法，其核心思想是利用全体观测数据，对目标模型参数进行整体优化，使模型在统计意义上尽可能接近数据分布。该方法通过度量点云样本与几何模型之间的误差，并在全局范围内最小化误差累积值，从而获得模型参数的最优估计结果。由于该过程充分利用了所有样本信息，最小二乘法在噪声分布较为理想、数据一致性较高的情况下，通常能够获得较高的拟合精度。在此基础上，Gu 等[11]采用最小二乘准则对点云数据进行几何模型拟合，通过解析求解模型参数实现目标结构的精确估计。该方法在数据质量较高、离群点比例较低的条件下表现出良好的拟合效果，但在复杂场景中，其对异常样本敏感的问题仍然存在。

1.3.2　基于随机抽样一致的鲁棒曲面拟合

针对最小二乘法在异常点存在时易受干扰的问题，魏英姿等[19]将 RANSAC 算法用于点云平面参数估计，通过内外点判别机制有效降低了离群点对拟合结果的影响。随机抽样一致性(RANSAC)是一种面向含有大量离群点数据的鲁棒模型估计方法，其核心目标是在噪声和异常点广泛存在的情况下，仍然能够可靠地估计模型参数。与最小二乘法不同，RANSAC 不依赖于全体样本的整体优化，而是通过“假设–验证”的方式逐步筛选有效数据。

在 RANSAC 算法中，点云样本通常被划分为内点(inliers)与外点(outliers)。内点指符合目标几何模型约束的数据点，而外点则是不满足模型假设的异常样本。算法首先从数据集中随机选取最小样本子集，用于生成候选模型；随后计算其余样本到该模型的误差，并根据预设阈值判断其是否为内点。常用的一致性度量形式可表示为式(8)。

$$|f(P_i,\theta)|<\varepsilon \tag{8}$$

式中：P_i 表示点云样本，θ为模型参数，ε为内点判定阈值。

通过多次随机采样与一致性评估，RANSAC 选择内点数量最多或误差最小的模型作为最终估计结果。由于模型参数主要由内点集合决定，外点对估计结果的影响被显著削弱，因此该算法在离群点比例较高的情况下仍能保持稳定的模型估计性能。

相比于基于最小二乘准则的方法，RANSAC 不

需要对噪声分布作出假设，在复杂点云环境中具有更强的鲁棒性和适应能力。因此，该算法被广泛应用于点云平面提取、几何结构拟合以及复杂场景建模等任务中。

综上所述，最小二乘法与 RANSAC 在点云曲面拟合任务中各具特点。最小二乘法通过利用全部样本数据进行整体优化，在噪声分布较为理想且离群点比例较低的情况下能够获得较高的参数估计精度；而 RANSAC 算法通过随机采样与内外点判别机制对异常样本具有较强的鲁棒性，在复杂场景或离群点较多的情况下能够获得更加稳定的拟合结果。因此，在实际应用中应根据点云数据质量及离群点分布情况选择合适的拟合方法，以实现修剪表面的可靠估计。

1.4 修剪点的提取

机械臂的运动规划需要空间中具体点的坐标，对于要覆盖的曲面而言，一般先对曲面进行网格化处理，取网格形心作为修剪点。为了提高修剪效率，将在拟合球面外的绿篱点云沿法向投影于球面，并将含有投影点的网格作为有效网格，取有效网格的形心作为实际修剪点（如图 3 所示）。

2 真实复杂场景验证

2.1 验证数据集构建及预处理

2.1.1 原始数据采集

绿篱的点云数据集来源于回龙观地铁站（40°04′15″N，116°20′09″E）路边绿篱，绿篱植物主要为冬青卫矛（*Euonymus japonicus*）和小叶黄杨（*Buxus sinica*）。如图 4 所示，使用 iPhone 15 Plus 缓慢环绕目标拍摄视频[20]，获得原始视频数据，分辨率为 1 920 × 1 080 像素，帧率为 30 帧/秒。

2.1.2 点云数据获取

对 2.1.1 中获得的视频数据进行抽帧，根据视频拍摄情况，每秒视频保留两帧及以上，并检查抽帧后得到的图像，将模糊或含有明显遮挡的图像删除。随后将图像数据使用 colmap 进行训练，获取每张图像原始相机位姿，并得到如图 5 所示的稀疏点云。

随后 NeRFstudio 对 colmap 的训练结果进行训练，训练得到如图 6 所示的结果。该结果并非传统意义上的三维网格或点云模型，而是一个经过优化的神经网络参数集合。该模型以隐式方式表示场景的连续三维辐射场函数，可根据输入的空间坐标与视角方向，预测对应位置的体密度与颜色值，从而实现任意视角的新视图合成。最后再从 NeRFstudio 训练得到的神经辐射场导出千万级的三维点云。数据集原始数据包含原始方形绿篱点云场景 9 组，球形绿篱 11 组。

2.1.3 数据增强

为了增强训练模型的泛化能力，使用体素网格下采样、随机采样、均匀分布采样 3 种方式对原千万级点云进行下采样至十万级以提高训练效率，并对下采样后的点云做如图 7 所示随机平移、旋转、缩放、抖动以及随机裁剪 5 种方式的数据增强处理。最终得到数据增强后的点云共 360 组。

2.1.4 数据集标注及构建

CloudCompare 是一款开源的 3D 点云处理软件，广泛应用于点云数据的可视化、分析和处理，适用于需要处理大规模点云数据、进行数据标注和分割的任务。本研究使用 CloudCompare 对含有绿篱点云的场景进行数据标注，以构建绿篱修剪语义分割数据集，具体步骤如下。

（1）点云文件导入 CloudCompare。原始的重建点

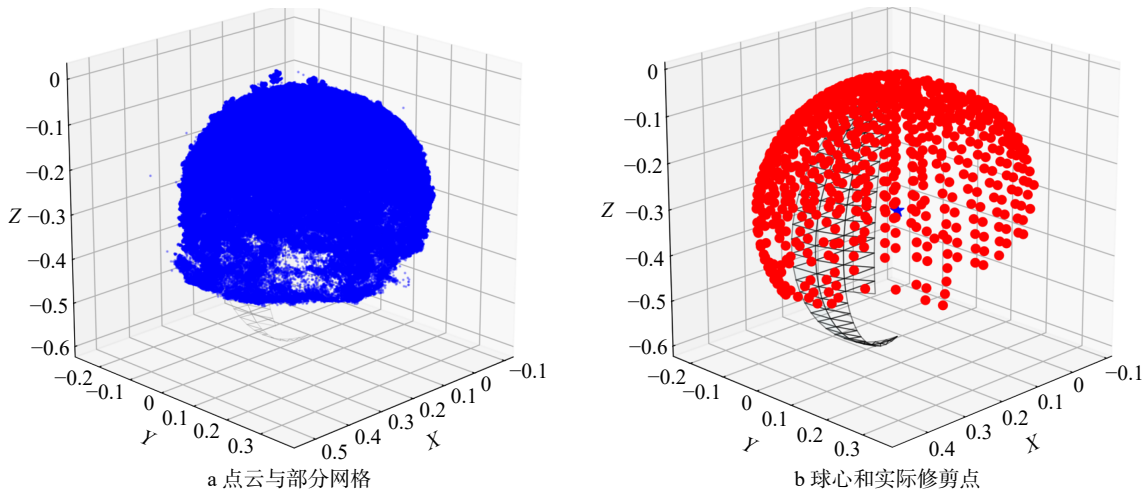


图 3 拟合面网格化及修剪点提取

Fig. 3 Fitted surface meshing and trim point extraction



图 4　采集路径示意图

Fig. 4　Schematic diagram of the acquisition path

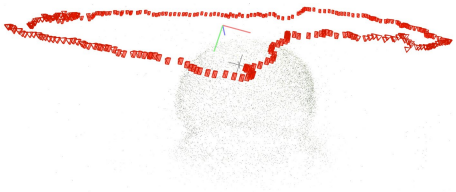


图 5　COLMAP 训练结果

Fig. 5　COLMAP training results

云数据格式为 ply 格式，将其导入 CloudCompare 中。

（2）选择分割标注区域。将目标场景点云标注划分成 3 类：地面（Ground）、球形绿篱（Ball）、方形绿篱（Cube）。在工具栏中，选取裁剪工具进行点云裁剪。如图 8a 所示，框选出绿篱点云作为裁剪对象。

由于修剪主要发生在绿篱含有叶片的部分，同时 PointNet++在训练时，输入的数据为点的坐标和



图 6　NeRFstudio 训练结果

Fig. 6　NeRFstudio training results

颜色信息，靠近地面的枝条不在需要修剪的范围内，在选取裁剪区域的时候，靠近地面且不带有叶片的部分应当划分至 Ground 类别中。

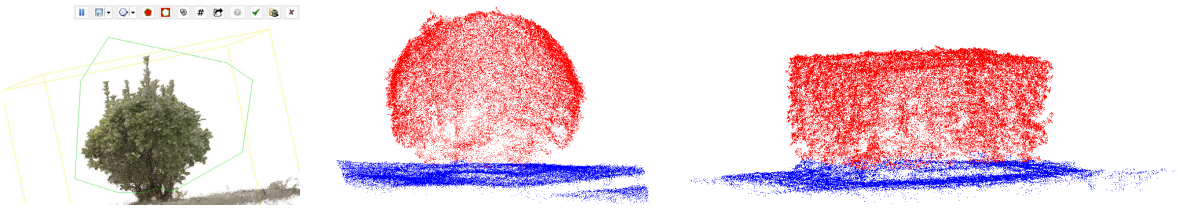
裁剪完成后，将原始场景点云划分为 Ground、Ball 和 Cube，分成 3 组点云。通过选择工具栏中的 Add constant SF，为每一类别点云定义标签（label）符号以及对应的 label 值，其中 Ground、Ball 和 Cube 三类分别被分配为 0、1 和 2 的 label 值，并生成相应的标量场。在完成点云数据的标签注释后，将结果以 x、y、z、R、G、B、label 值、N_x、N_y、N_z 九列数据的形式保存为“TXT”格式，其中，x、y、z 为三维坐标，R、G、B 为颜色信息，N_x、N_y、N_z 为法向量坐标。后对 txt 文件使用 python 脚本进行处理，去除后 3 列法向量信息，得到需要的含有 7 列数据的“TXT”格式点云文件，如图 9 所示。最终，共构建了包括 360



红框为随机裁剪区域。

图 7　原始点云及数据增强

Fig. 7　Original point clouds and data augmentation



a 标注方法 b 含有球形绿篱场景的标注结果 c 含有方形绿篱场景的标注结果

图 8 标注方法及结果

Fig. 8 Annotation methods and results

个场景的点云语义分割数据集。

2.2 实验设计及评价指标

2.2.1 实验设计

为验证本文提出方法在绿篱智能修剪任务中的有效性，实验从语义分割、修剪表面拟合以及修剪点提取三个方面进行设计。

在语义分割实验中，采用构建的 360 组绿篱点云数据集进行网络训练与测试。按照 8∶2 的比例将数据集划分为训练集和测试集，其中 80% 的样本用于网络训练，20% 的样本用于网络性能评估。为了验证改进策略的有效性，将所提出的 Hedge-PointNet 与原始 PointNet++进行对比实验。两种网络在相同数据集和相同训练参数条件下进行训练与测试，通过对比不同网络的分割结果评估改进网络在绿篱场景点云语义分割任务中的性能。

在修剪表面拟合实验中，从语义分割结果中提取球形绿篱(Ball)类别的点云数据，分别采用最小二乘法和 RANSAC 进行球面拟合，并计算对应的球面参数。通过比较两种方法的拟合效果和误差情况，分析不同拟合方法在存在噪声点云条件下的适用性及稳定性。

在修剪点提取实验中，以拟合得到的目标修剪曲面为基础，对曲面进行网格化处理并计算网格中心点作为候选修剪点。同时，将曲面外的绿篱点云沿曲面法向方向投影至目标曲面，并筛选包含投影点的有效网格，以其中心点作为最终修剪点。通过分析修剪点的空间分布及数量变化，评估所提出修剪点提取方法在减少无效修剪操作方面的效果。

通过上述实验，分别从目标识别、轮廓估计和作业点生成 3 个方面对本文方法进行验证，以说明该技术路线在绿篱智能修剪任务中的可行性与有效性。

2.2.2 评价指标

通过比较原始 PointNet++与 Hedge-PointNet 测试输出的类别平均准确率(Average Class Accuracy，ACC)、平均交并比(mean Intersection over Union，mIoU)及各类别交并(Intersection over Union，IoU)比[21]，以验证 Hedge-PointNet 在绿篱修剪场景对于 PointNet++的先进性；通过球形绿篱点云数据集评估随机抽样一致性算法球面拟合的方法，并将其与最小二乘法进行比较，从而比较两种不同算法在绿篱修剪球面拟合任务中的不同特性；通过对原始修剪点数量和实际修剪点数量的比较验证修剪点提取方

1	2	3	4	5	6	7
coord. X	coord. Y	coord. Z	Red (0-255)	Green (0-255)	Blue (0-255)	Scalar
-0.117850	0.208784	-0.189204	126	126	97	2
-0.028082	-0.110019	-0.356804	83	85	73	2
-0.073233	0.279665	-0.146887	67	68	47	2
-0.174377	-0.079341	-0.204914	98	101	91	2
-0.186840	-0.114027	-0.447827	221	223	231	0
0.170172	-0.113071	-0.439290	41	34	33	0
0.055340	-0.302984	-0.437629	206	207	202	0
0.364146	0.245416	-0.116339	155	154	117	2
0.405270	0.114043	-0.207434	102	97	97	2
-0.113387	0.172175	-0.306595	133	137	92	2
0.176198	-0.213632	-0.435651	200	203	213	0
0.072586	-0.137338	-0.165365	42	40	39	2
0.094989	0.010520	-0.137288	142	142	118	2
-0.061071	-0.030622	-0.412239	66	63	55	0

图 9 TXT 数据格式

Fig. 9 TXT data format

法的先进性。

ACC 和 mIoU 是评估点云语义分割网络常用的评估指标。ACC 是各类别分类准确率的算术平均值，具体计算方式见式(9)。该指标用于评估网络在不同类别上的分类均衡性，以反映其对各类别点云数据的学习能力。较高的 ACC 说明网络在所有类别上均表现稳定，而不是仅对某些类别具有较高精度。mIoU 表示所有类别的平均交并比(IoU)，即预测类别与真实类别的重叠度[22]，计算方式如式(10)所示。mIoU 越高，表示网络的预测与实际目标越接近。

$$\mathrm{ACC}=\frac{1}{m}\sum_{i=1}^{m}\frac{N_{\mathrm{TP}i}}{N_i} \tag{9}$$

$$\mathrm{mIoU}=\frac{1}{m}\sum_{i=1}^{m}\frac{N_{\mathrm{TP}i}}{N_{\mathrm{TP}i}+N_{\mathrm{FP}i}+N_{\mathrm{FN}i}} \tag{10}$$

式中：m 是类别的总数，N_i 是该类别点云中所有点的总数，$N_{\mathrm{TP}i}$ 是真阳性，$N_{\mathrm{FP}i}$ 是假阳性，$N_{\mathrm{FN}i}$ 是假阴性。

拟合球面旨在找出适合输入点云的修剪表面。为了验证算法的精度和有效性，使用均方根误差(R_{MSE})对算法准确度进行评估，均方根误差的计算见式(11)。

$$R_{\mathrm{MSE}}=\sqrt{\frac{\sum_{i=1}^{n}(d_i-r)^2}{n}} \tag{11}$$

式中：d_i 为点到拟合球心的欧氏距离，r 为拟合球面的半径，n 为点云中点的总数。

修剪效率提升率通过实际修剪点数量与原始网格中心点数量之间的比例关系进行衡量，记修剪效率提升率为 η，实际修剪点数量为 e_1，原始修剪点数量为 e_0，则 η 可用式(12)进行计算。

$$\eta=(1-e_1/e_0)\times 100\% \tag{12}$$

该指标用于表征在保证修剪轮廓精度前提下所减少的无效修剪动作比例。

3　结果与分析

3.1　修剪场景点云语义分割结果

通过表 1 结合图 10 中两种网络分割的可视化比较结果可知，原始 PointNet++明显不适用绿篱修剪场景的语义分割任务，而 Hedge-PointNet 在绿篱修剪场景的语义分割任务有较好的表现。

表 1　原始 PointNet++与 Hedge-PointNet 测试结果对比

Tab. 1　Comparison of test results between original PointNet++ and Hedge-PointNet

评估指标	PointNet++	Hedge-PointNet
IoU_1	0.329	0.958
IoU_2	0.117	0.993
IoU_3	0.004	0.961
mIoU	0.150	0.971
ACC	0.323	0.984

注：IoU_1为标签为cube的点云测试结果的交并比，IoU_2为标签为ball的点云测试结果的交并比，IoU_3为标签为ground的点云测试结果的交并比，mIoU为平均交并比，ACC是各类别分类准确率的算术平均值。

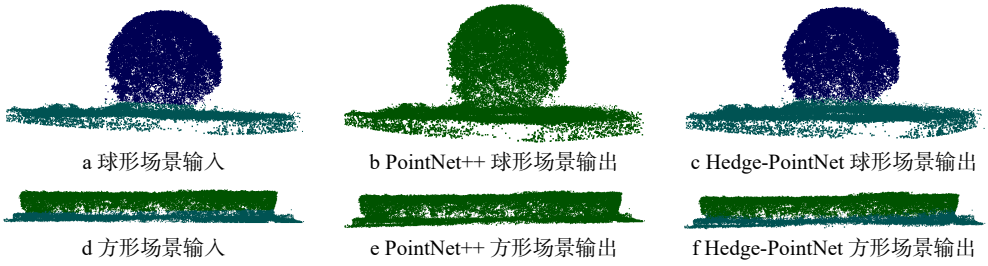
从语义分割结果来看，改进后的 Hedge-PointNet 有效解决了原始 PointNet++在小尺度场景中由于采样方式不适配而导致部分类别 IoU 与训练阶段明显不匹配的问题。尽管 PointNet++在输出层同样采用 Softmax 函数进行类别概率归一化，但其 Softmax 主要用于最终分类输出，并未对点级概率信息进行显式建模与融合[17]；相比之下，Hedge-PointNet 将 Softmax 输出作为点级类别置信概率进行累积建模，并引入多轮推理融合机制，使概率信息参与测试阶段的决策优化，从而提升了复杂结构区域的分割稳定性和精细表达能力。

3.2　球面拟合及修剪点提取

在球面拟合的实验中，随机抽样一致性算法表现出明显优势。随机抽样一致性算法的 R_{MSE} 为 0.005 1 m，相较最小二乘法(R_{MSE} = 0.154 9 m)，降低了 96.7%，表明 RANSAC 在有部分噪声的点云场景中有较强的鲁棒性(表 2)。

对于同一个曲面，修剪点数量大小可以从侧面反映修剪效率(表 3)。实际修剪点数量为 261，原始修剪点(即全部三角网格中心点)数量为 722，计算得到修剪效率提升率η为 63.9%。图 11a 展示的是修剪点点云的可视化结果，图 11b 展示的是所提取修剪点的空间坐标信息。

图 12 为两种方法对绿篱点云拟合球面的可视



a 球形场景输入　b PointNet++ 球形场景输出　c Hedge-PointNet 球形场景输出

d 方形场景输入　e PointNet++ 方形场景输出　f Hedge-PointNet 方形场景输出

图 10　PointNet++与 Hedge-PointNet 语义分割结果比较

Fig. 10　Comparison of semantic segmentation results between PointNet++ and Hedge-PointNet

表 2 不同算法拟合曲面的均方根误差

Tab. 2 Root mean square error of surface fitting by different algorithms

评估指标	最小二乘法	随机抽样一致性算法(RANSAC)
R_{MSE}/m	0.154 9	0.005 1

表 3 修剪点数量

Tab. 3 Number of trimming points

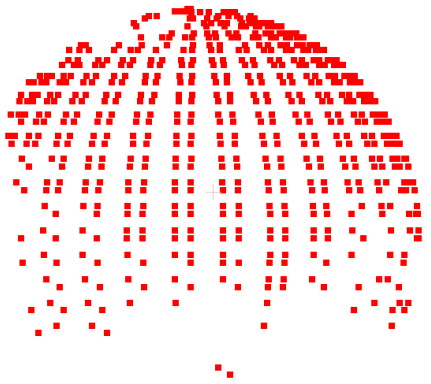
评估指标	原始修剪点	实际修剪点
数量	722	261

化结果，RANSAC 在拥有较小的均方根误差的同时，拟合出的球面半径也大于最小二乘法拟合出的球面半径。另外，在最小二乘法拟合球面的最上方明显存在空白区域，即存在较多点云位于拟合球面内部，即存在无法修剪的区域，会导致修剪后的结果与预期形状有较大差距。

从拟合结果来看，基于 RANSAC 得到的球面模型相较最小二乘法具有更小的均方根误差，表明 RANSAC 在存在离群点的复杂绿篱点云环境中具有更强的鲁棒性。均方根误差降低 96.7%，说明该方法在定位修剪目标曲面时能够有效抑制异常点干扰，提高拟合精度。同时，实际修剪点数量占全部三角网格中心点的 36.1%，能够显著减少无效修剪动作，体现了该方法在效率优化方面的优势。

4 结 论

本研究针对绿篱智能修剪过程中目标轮廓难以自主判别的问题，提出了一种基于语义分割与随机抽样一致性算法(RANSAC)相结合的绿篱修剪点提取技术框架。首先构建 Hedge-PointNet 语义分割网络，对输入场景点云进行语义分割，实现绿篱目标修剪形态的自主判别；在此基础上，利用 RANSAC 对



a 修剪点点云

```
PRUNING POINTS COORDINATES

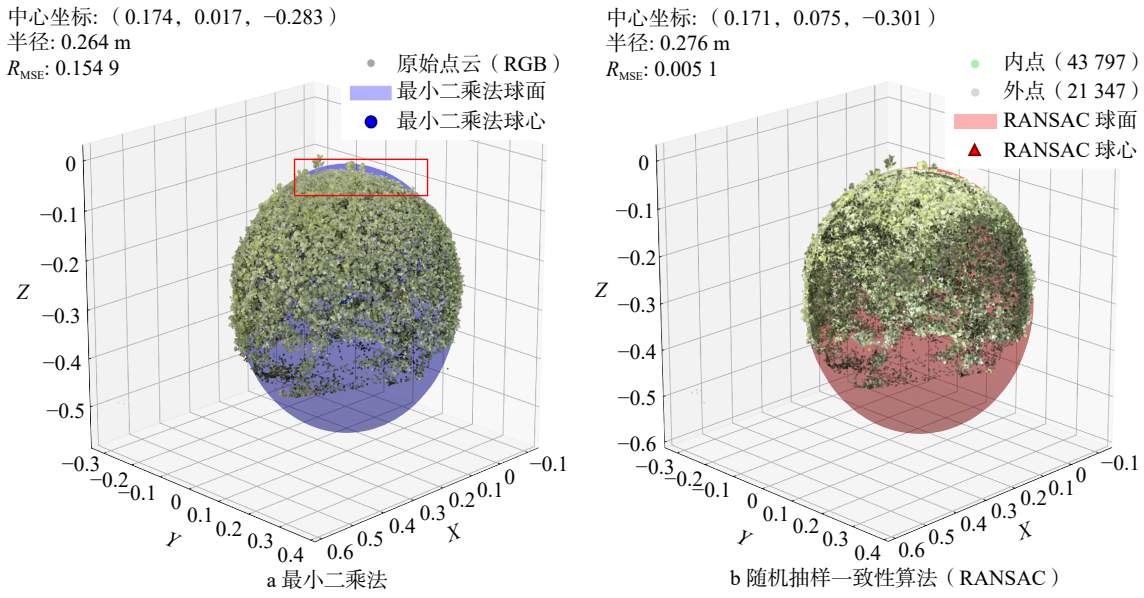
Total Pruning Points: 607
Sphere Center: (0.170691, 0.074044, -0.300886)
Sphere Radius: 0.276410

Index  Triangle Index  X         Y         Z         Distance to Center
0      4               0.239261  0.078302  -0.033608  0.275967
1      7               0.275892  0.088685  -0.046331  0.275826
2      8               0.294662  0.082361  -0.054696  0.275767
3      9               0.302366  0.092572  -0.059369  0.275703
4      10              0.320342  0.084256  -0.069641  0.275634
5      11              0.327296  0.096242  -0.075240  0.275561
6      12              0.344267  0.086031  -0.087297  0.275486
7      13              0.350389  0.099652  -0.093755  0.275409
8      14              0.366157  0.087665  -0.107457  0.275332
9      15              0.371376  0.102761  -0.114699  0.275254
10     16              0.385756  0.089140  -0.129884  0.275177
11     17              0.390010  0.105534  -0.137826  0.275102
12     18              0.402833  0.090438  -0.154317  0.275029
13     19              0.406073  0.107938  -0.162865  0.274960
14     20              0.417188  0.091544  -0.180468  0.274896
15     21              0.419376  0.109944  -0.189522  0.274836
16     22              0.428654  0.092444  -0.208030  0.274783
```

b 修剪点坐标信息

图 11 修剪点信息提取

Fig. 11 Extraction of trim point information



a 最小二乘法 b 随机抽样一致性算法（RANSAC）

图 12 不同算法球面拟合结果对比

Fig. 12 Comparison of sphere fitting results using different algorithms

目标表面进行几何模型拟合，并结合曲面网格化处理完成修剪点的自动提取，为机器人修剪作业提供具体的空间坐标信息。本研究的主要结论有以下 3 点。

（1）通过构建改进的 Hedge-PointNet 语义分割网络，对绿篱场景点云进行结构化理解，可以显著提升点云语义识别的准确性。实验结果表明，与原始 PointNet++相比，该网络在绿篱修剪场景中的平均交并比由 0.150 提升至 0.971，类别平均准确率由 0.323 提升至 0.984，实现了对球形绿篱、方形绿篱及地面类别的稳定识别，为后续修剪表面拟合提供了可靠的语义基础。

（2）在获得目标绿篱点云后，引入 RANSAC 对目标修剪表面进行几何拟合，可以有效降低点云中的离群点对模型估计的影响，使拟合结果更为稳定。实验结果表明，RANSAC 算法拟合球面的均方根误差仅为 0.005 1 m，相较最小二乘法的 0.154 9 m 降低了 96.7%，显著提高了目标曲面的估计精度。

（3）在曲面拟合基础上，通过曲面网格化与投影筛选机制提取实际修剪点，可进一步减少不必要的修剪操作。实验结果显示，最终实际修剪点数量为 261 个，仅占原始网格中心点 722 个的 36.1%，在保证修剪轮廓精度的同时，有效减少了约 63.9% 的无效修剪操作，从而提高了整体修剪效率。

综上，本文方法通过“语义判别—几何拟合—目标点提取”的技术路径，实现了从绿篱场景理解到作业点生成的逐步转化，使得修剪轮廓的确定不再依赖于人工设定的理想模型，从而提升了系统的自主性与智能化程度。该方法在绿篱智能修剪场景中验证了其有效性，同时也为其他需要进行目标轮廓识别与操作决策的三维作业任务提供了可借鉴的技术方案。

从工程应用的角度看，本文提出的方法可作为绿篱自动修剪装备中的前端感知与决策模块，部署于由三维感知单元、控制器、机械臂及末端修剪执行器构成的作业系统。在实际应用场景下，可通过移动平台搭载的相机或深度传感器获取绿篱点云数据，经车载工控机或嵌入式计算单元运行 Hedge-PointNet 分割、目标曲面拟合及修剪点生成算法，输出目标曲面参数和修剪点坐标，并进一步为轨迹规划和修剪执行提供输入。按照当前研究条件，本文方法更适用于绿篱周期性养护中的离线或准在线决策场景。后续研究可进一步引入绿篱病害、局部缺损及生长异质性等复杂工况变量，扩充多源数据集，并探索该视觉算法与机械臂、末端执行器及路径规划模块之间的协同机制，构建“感知—决策—执行”一体化系统，在真实园林场景中开展实机验证，以推动相关研究由算法验证向工程应用落地。

参　考　文　献

[1] 阚延鹏, 陈玉, 张新阳, 等. 回转型绿篱修剪机动力学分析及虚拟样机仿真 [J]. 甘肃农业大学学报, 2021, 56(2): 193−200.
Kan Y P, Chen Y, Zhang X Y, et al. Dynamic mechanics analysis and virtual prototype simulation of hedgerow pruning [J]. Journal of Gansu Agricultural University, 2021, 56(2): 193−200.

[2] Zahid A, Mahmud M S, He L, et al. Technological advancements towards developing a robotic pruner for apple trees: a review [J]. Computers and Electronics in Agriculture, 2021, 189: 106383.

[3] Gonzalez-de-Santos P, Fernández R, Sepúlveda D, et al. Field robots for intelligent farms: inhering features from industry [J]. Agronomy, 2020, 10(11): 1638.

[4] Kaljaca D, Vroegindeweij B, van Henten E. Coverage trajectory planning for a bush trimming robot arm [J]. Journal of Field Robotics, 2020, 37(2): 283−308.

[5] Bac C W, van Henten E J, Hemming J, et al. Harvesting robots for high-value crops: state-of-the-art review and challenges ahead [J]. Journal of Field Robotics, 2014, 31(6): 888−911.

[6] van Henten E J, Bac C W, Hemming J, et al. Robotics in protected cultivation [J]. IFAC Proceedings Volumes, 2013, 46(18): 170−177.

[7] 罗海风, 张琦, 肖力玮, 等. 路侧绿篱修剪机器人的设计与试验评估 [J]. 北京林业大学学报, 2025, 47(5): 1−13.
Luo H F, Zhang Q, Xiao L W, et al. Design and experimental evaluation of a roadside hedge trimming robot [J]. Journal of Beijing Forestry University, 2025, 47(5): 1−13.

[8] 王克涛, 陈世锋, 陈贵, 等. 基于 YOLOv5s 的园林球形绿篱检测方法 [J]. 中国农机化学报, 2024, 45(8): 262−269.
Wang K T, Chen S F, Chen G, et al. Detection method of garden spherical hedge based on YOLOv5s [J]. Journal of Chinese Agricultural Mechanization, 2024, 45(8): 262−269.

[9] 张佳承, 韦锦, 陈义时. 改进 YOLOv8 的实时轻量化鲁棒绿篱检测算法 [J]. 计算机工程, 2025, 51(7): 362−374.
Zhang J C, Wei J, Chen Y S. Improved YOLOv8 real-time lightweight robust hedge detection algorithm [J]. Computer Engineering, 2025, 51(7): 362−374.

[10] Botterill T, Paulin S, Green R, et al. A robot system for pruning grape vines [J]. Journal of Field Robotics, 2017, 34(6): 1100−1122.

[11] Gu J, Zhang B, Wang Y, et al. Hedge three-dimensional reconstruction and motion control technology for trimming robot [J]. Computers and Electronics in Agriculture, 2024, 227: 109632.

[12] Sampaio G S, Silva L A, Marengoni M. 3D reconstruction of non-rigid plants and sensor data fusion for agriculture phenotyping [J]. Sensors, 2021, 21(12): 4115.

[13] Tabb A, Medeiros H. A robotic vision system to measure tree

traits[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Vancouver. IEEE, 2017: 6005−6012.

[14] Wang Y, He Z, Cao D, et al. Coverage path planning for kiwifruit picking robots based on deep reinforcement learning [J]. Computers and Electronics in Agriculture, 2023, 205: 107593.

[15] Nguyen T N, Huynh H H, Meunier J. 3D reconstruction with time-of-flight depth camera and multiple mirrors [J]. IEEE Access, 2018, 6: 38106−38114.

[16] Lehnert C, English A, McCool C, et al. Autonomous sweet pepper harvesting for protected cropping systems [J]. IEEE Robotics and Automation Letters, 2017, 2(2): 872−879.

[17] Charles R Q, Li Y, Hao S, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space[C]//Advances in Neural Information Processing Systems. Long Beach: Curran Associates Inc. , 2017, 30: 5099−5108.

[18] Charles R Q, Hao S, Mo K, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 77−85.

[19] 魏英姿, 刘晓莉. 基于随机抽取一致性的稳健点云平面拟合 [J]. 北京工业大学学报, 2014, 40(3): 400−403.
Wei Y Z, Liu X L. Robust plane fitting of point clouds based on RANSAC [J]. Journal of Beijing University of Technology, 2014, 40(3): 400−403.

[20] Zhu W, Ma R, An J, et al. Three-dimensional reconstruction and parameters extraction of walnut (*Juglans regia* L.) branches based on Neural Radiation Fields [J]. European Journal of Agronomy, 2025, 169: 127693.

[21] 齐建东, 石成城, 吴鹏. TSIT-PatchTST 模型: 一种净生态系统交换量 (NEE) 缺失值插补方法 [J]. 北京林业大学学报, 2025, 47(2): 105−118.
Qi J D, Shi C C, Wu P. TSIT-PatchTST model: a missing value interpolation method for net ecosystem exchange (NEE) [J]. Journal of Beijing Forestry University, 2025, 47(2): 105−118.

[22] Zhu W, Bai X, Xu D, et al. Pruning branch recognition and pruning point localization for walnut (*Juglans regia* L.) trees based on point cloud semantic segmentation [J]. Agriculture, 2025, 15(8): 817.

（责任编辑 吴 娟
责任编委 陈志泊）