

基于树顶点多约束的地基点云热带红树林单木分割

刘王军^{1,2,3}, 陈一平¹, 王朝磊¹, 张吴明¹, 王成^{2,3}

1. 中山大学 测绘科学与技术学院, 珠海 519082;

2. 中国科学院空天信息创新研究院 数字地球重点实验室, 北京 100094;

3. 中国科学院大学 资源与环境学院, 北京 100049

摘要: 热带红树林是生产力最高、最富有生物多样性的森林资源之一, 红树林森林资源调查能为森林资源的科学管理和保护提供数据支撑, 准确的单木分割是二类森林资源调查的前提。地基激光雷达TLS (Terrestrial Laser Scanning) 能够提供海量、高精度的三维点云数据。然而, 点云数据存在无规则、近密远疏且因遮挡导致的数据残缺等问题。并且, 红树林场景复杂, 冠层交错, 树木互相遮挡, 现有研究方法不适用于红树林TLS点云。本研究创新性地结合深度学习与传统算法, 提出了一种针对红树林复杂场景TLS点云的高精度单木分割框架。该框架首先利用深度学习网络RandLA-Net进行地面滤波和样地枝叶分离, 其次通过连通域分割方法进行主干分割, 最后通过提出的基于树顶点多约束模块实现单木分割。本文选取了中国海南7个红树林样地进行算法的精度评价, 并与两种经典算法进行对比分析。实验结果显示, 本文方法的总体精度达到0.87, 大幅高于两种经典算法, 证明了本文方法的有效性和可靠性。

关键词: 热带红树林, 地基激光雷达, 点云, 单木分割, 深度学习

中图分类号: TP701/P2

引用格式: 刘王军, 陈一平, 王朝磊, 张吴明, 王成. 2026. 基于树顶点多约束的地基点云热带红树林单木分割. 遥感学报, 30(5): 1249-1261

Liu W J, Chen Y P, Wang C L, Zhang W M and Wang C. 2026. Individual tree segmentation of terrestrial tropical mangrove forest point clouds based on multiple constrains at tree tops. National Remote Sensing Bulletin, 30(5): 1249-1261 [DOI: 10.11834/jrs.20244054]

1 引言

红树林是一种生长在热带和亚热带的滩涂浅滩区域的湿地木本植物群落, 是全球生产力最高的生态系统之一, 其具有繁茂的枝干, 是许多沿岸动物的觅食、栖息和繁殖的场所, 为自然和人类社会提供了大量的经济和生态价值。目前, 全球有超过70种类别的红树林, 覆盖20万km², 然而它们目前面临种植结构单一, 生态系统质量不高, 种植红树林成活率低, 极端天气和病虫害等的威胁 (Duke等, 2007)。就中国而言, 由于农田和养殖池扩张等因素, 1973年—2000年中国红树林面积减少了38% (贾明明等, 2021)。其中, 中国海南省涵盖了36种类别的红树林, 是红树林种类最多的地区, 主要分布在海口、文昌、三亚等

市。研究发现, 中国海南岛红树林重点保护区的红树林面积在1987年—2017年间减少了9.3% (Liao等, 2019)。红树林的大量减少导致其生态和经济价值损失, 因此, 合理开发红树林并进行精确调查与科学管理对可持续发展目标具有重要意义。

森林资源调查能为森林资源的科学管理提供数据支撑。传统的森林资源调查一般采用目视解译航空像片, 或者实地森林调查等手段, 需要耗费大量的人力、物力, 面临调查环境复杂, 调查周期长, 调查效率低等问题。20世纪70年代开始, 中国逐步应用计算机和卫星遥感技术进行森林资源调查。遥感技术可以有效完成复杂时空尺度海量信息的收集处理, 其与森林资源调查研究

收稿日期: 2025-02-23; 预印本: 2025-07-25

基金项目: 国家自然科学基金(编号:42371343)

第一作者简介: 刘王军, 研究方向为激光雷达数据处理及应用。E-mail: liuwangjun23@mails.ucas.ac.cn

通信作者简介: 陈一平, 研究方向为点云处理。E-mail: chenyp79@mail.sysu.edu.cn

的交叉、融合能够大大提高复杂时空尺度上的森林资源研究的表达能力(高广磊等, 2013)。近年来, 利用光学遥感图像进行森林资源调查的技术逐渐成熟, 如森林覆盖度计算(Boyd等, 2002)、树种分类(Ahlswede等, 2023)、森林蓄积量估测(McRoberts等, 2013)。然而, 虽然光学遥感影像能对森林资源进行大尺度、长时序的区域性统计调查, 但是由于光学遥感数据只能获取冠层顶部二维信息和外围冠层轮廓, 难以进行精确的单木级森林资源调查。近年来, 激光雷达技术迅速发展, 被广泛用于自动驾驶、实景三维和智慧城市等领域。由于其能够高效、精确地刻画森林三维结构, 许多学者利用其开展单木尺度的森林资源调查研究, 例如树高测量(Kwak等, 2007)、树冠结构测量(Popescu等, 2003)等。利用激光雷达进行森林资源调查主要有地基激光雷达 TLS (Terrestrial Laser Scanning) 和机载激光雷达 ALS (Airborne Laser Scanning) 两种手段。相比于 ALS, TLS 能够获取红树林冠层以下更加丰富的细节, 更适用于单木参数计算, 从而更好地服务于红树林资源的保护和管理(Guo等, 2018)。现有单木分割算法可以分为传统算法和基于深度学习方法两类。

传统的点云单木分割算法可以分为以下两种思路: 基于冠层高度模型 CHM (Canopy Height Model) 的分割方法和基于点云的分割方法。基于 CHM 的分割方法的主要思想是从归一化的点云中计算冠层高度栅格图, 由于单木点云的冠层高度呈现中心高四周低的特征, 基于该特点采用各种图像处理方法提取树顶, 并进行树冠分割。常见的分割方法有区域生长法(Hyyppä等, 2001)、分水岭法(Pouliot和King, 2005)、基于图论的分割方法(Strimbu和Strimbu, 2015)等。基于 CHM 的方法将点云转化为图像, 将三维数据处理问题转化为二维数据处理问题, 能够有效简化问题, 提高计算速度, 同时也存在不足。CHM 的生成需要对原始点云建立格网, 然而格网属性值由格网内点云高度特征确定, 因此这种将数据由三维压缩到二维的方法, 不可避免地导致信息损失。同时, 由于此类方法在生成 CHM 时需要进行插值, 引入误差, 导致分割精度降低。基于以上不足, 许多学者设计了诸如 K-Means (Morsdorf等, 2009), 自下而上区域生长(Lu等, 2014), 归一化割(Reitberger等, 2009)等基于点云的单木分割方法。无论是基于 CHM 的

分割方法还是基于直接处理点云的分割方法, 都依赖于人工设计特征, 因此一些隐含的, 较为复杂的特征则难以被运用。

近年来, 随着深度学习的快速发展, 其在许多领域中被广泛应用。由于深度学习在特征提取中的突出性能, 许多学者也利用其开展林业研究。Wang等(2019)将树干点云投影, 利用 FasterR-CNN (Ren等, 2015) 网络进行树干检测。基于检测到的树干点云进行区域生长, 得到完整的树干, 再使用基于距离的聚类方法, 聚合叶片点云实现单木分割(Wang等, 2019)。Windrim等(2020)在对机载点云先进行地面滤波, 之后将植被点云进行分块处理, 并进行体素化, 将每个体素转化为二维的 BEV (Bird's Eye View) 栅格图, 使用 Faster R-CNN 进行检测, 最后垂直投影至点云实现单木分割(Windrim和Bryson, 2020)。以上两种同类方法, 通过投影再检测, 损失了树木的高度几何信息, 影响了算法的精度。Chen等(2021)将点云体素化, 分为苗圃基地、寺庙林园、混合林区、落叶林 4 个类别, 利用 PointNet (Qi等, 2017) 对体素点云进行识别, 识别为树木的体素再利用树冠的梯度信息检测树冠边界(Chen等, 2021)。Luo等(2022)采用图卷积神经网络进行地面滤波, 相比于经典地面滤波算法, 该算法无需进行参数调整。为了提取树木垂直结构信息, 该方法采用一种自上而下切片模块, 之后使用多特征通道来保留点云不同的特征, 最后使用多分支网络来融合多通道信息实现单木分割(Luo等, 2022)。

综上所述, 传统方法如基于 CHM 进行局部最大值检测等方法在简单场景样地中取得了较好表现, 但是红树林复杂场景冠层交错严重, 树冠上部特征弱, 目前国内外鲜有基于 TLS 点云的红树林单木分割算法的研究。针对以上挑战, 本研究提出了一种基于红树林 TLS 点云数据特点的单木分割框架算法。该框架充分利用了深度学习提取潜在特征的能力以及 TLS 点云能够较好地刻画树干特征的优势, 在红树林场景中取得了较好表现。主要有以下两点创新:

(1) 提出了一个新颖的深度学习与传统算子相结合的红树林单木分割框架。该框架通过深度学习局部特征聚合以及传统算子双阈值约束, 解决了基于 TLS 的红树林复杂场景难以提取单木的问题, 对红树林进行有效的单木分割。充分的实验表明,

相比于两种经典算法，精度分别提高0.72和0.29。

(2) 提出了一种新的基于树顶点多约束的单木

分割方法，通过多约束对大小树交错，遮挡导致的数据不全的红树林点云数据进行精确的单木分割。




图1 原始点云数据

Fig. 1 Original point cloud

2 研究原理与方法

红树林场景复杂，树冠交错，而TLS点云能够较好地刻画树干特征，且由于树干之间间距较大，可以在利用欧式距离聚类方法完成主干分割的基础上，再进行单木分割。因此，本文针对红树林点云数据的特点提出了深度学习与传统算法结合的高精

度复杂场景TLS点云单木分割方法。首先，将深度学习网络RandLA-Net (Hu等, 2020) 分别应用到地面滤波任务与森林点云样地尺度的枝叶分离任务。其次，根据枝叶分离的结果提取树木主干，利用连通域分割算法先进行主干分割，并以主干为中心进行树顶点检测。最后，根据提出的树顶点多约束方法实现单木分割，算法框架如图2所示。




图2 本文算法框架

Fig. 2 Algorithm frame work

2.1 基于RandLA-Net的地面滤波

随着深度学习的发展，许多学者基于深度学习进行地面滤波。例如Hu和Yuan (2016) 基于卷积神经网络 (CNN)，将点云转化为图像，使点云滤波问题变为图像分类问题，Jahromi等 (2011) 提出基于人工神经网络的点云滤波算法。目前直接处理点云的深度学习地面滤波算法普遍采用经典的PointNet (Qi等, 2017) 等网络，这些网络在规则场景中能达到较好的精度，但是对于复杂森林场景则存在处理速度慢、内存占用大、全局特征缺失等问题。因此，本文选取适用于复杂场景的点云处理网络RandLA-Net进行地面滤波任务的训练。

RandLA-Net的核心思想是首先对点云进行随机采样以降低点云密度，其次使用局部特征融合

保留损失的局部特征，使其在效率和精度上达到平衡，图3展示了RandLA-Net的网络结构。

随机采样可能会导致点云特征缺失，因此需要局部特征聚合模块进行补偿。局部特征聚合模块主要包括3个子模块：局部空间编码 (Local Spatial Encoding)、Attentive Pooling 和扩张残差块 (Dilated Residual Block)。

2.1.1 局部空间编码 (Local Spatial Encoding)

给定点云集合 P ，以及每个点的特征，局部空间编码模块能够将所有邻域点的 x , y , z 坐标进行编码，使得LocSE单元能学习局部几何模式，从而最终使整个网络能够有效地学习复杂的局部结构。其包含寻找邻域点、相对位置编码和点特征增强3个步骤。




图3 RandLA-Net地面滤波架构

Fig. 3 RandLA-Net ground filter architecture

2.1.2 Attentive Pooling

通过最大或平均池化聚合邻近特征会导致大量信息缺失,因此RandLA-Net网络采用注意力机制聚合相邻点的特征。该模块首先对每个特征集合设计一个共享函数来对每个特征计算唯一的注意力得分,再将各个特征及其注意力分数进行加权求和。

2.1.3 扩张残差块(Dilated Residual Block)

由于点云不断被随机采样,因此需要增大每个点的感受野,以保留输入点云的整体几何细节。因此RandLA-Net将多个局部空间编码、注意力池化以及跳跃连接组合在一起构成扩张残差块。

2.2 基于RandLA-Net的红树林样地枝叶分离

目前已有许多基于点云物理或几何特征进行枝叶分离的方法,例如用枝干点和树叶点的强度差异,特征值差异等,但是由于点云样地场景较为复杂,现有研究大部分是基于单木尺度进行枝叶分离,需先进行单木分割。RandLA-Net能够从复杂场景点云中提取隐含特征,因此本文基于RandLA-Net网络进行样地场景枝叶分离。

2.3 基于树顶点多约束的单木分割

红树林树冠交错严重,但是树干间距较大,可用欧氏距离聚类方法即可完成分割。本研究先使用连通域分割对上述枝叶分离得到的树干进行分割,再基于单木主干检测树顶点,最后基于树顶点约束进行单木分割。详细的算法介绍如下:

(1) 基于连通域分割对样地所有树木主干进行分割,得到单木主干。

(2) 以一定的高度对单木主干进行垂直分层,若检测到某层点云数量小于一定阈值,则判定到

达树顶点。

(3) 以树顶点为中心,三倍最小树冠半径为圆柱搜索半径进行圆柱邻域搜索。

(4) 对圆柱搜索内的所有点按高程由高到低排序进行处理。

(5) 若点到树顶点距离小于最小树冠半径,则判断为当前树点,若点到树顶点距离大于两倍最小树冠半径,则判断为非树点。

(6) 对于到树顶点距离大于最小树冠半径且小于两倍最小树冠半径的点,计算其与当前树点集和非树点集的最小距离,若离当前树点集的最小距离较小,则判断该点为当前树点。




图4 基于树顶点的单木分割流程图

Fig. 4 Algorithm flow-chart

3 研究区与数据

3.1 实验区基本情况

研究区域位于中国海南岛,地处热带,是中国红树林的分布中心,包含中国天然分布的36种

红树林，约为国内红树林总种类的 96%，其中，有半数以上树种仅在海南有天然分布。在海南，大部分种类的红树林分布在清澜湾保护区，占全球红树品种的 40%。该保护区中心坐标为 19°34'N，110°45'E，面积达 2948 ha，现为省级自然保护区。

3.2 LiDAR 数据采集

本研究所用数据采用 Rigel VZ-1000 进行采集，其主要参数如表 1 所示。Rigel VZ-1000 利用 ToF 技术实现对目标进行多回波测量，该设备重量 10 kg，最远扫描距达 1400 m，能提供每秒 30 万次测量，测量精度达 5 mm（100 m 距离处，一次单点扫描）。

表 1 TLS 设备说明

Table 1 Specification for the TLS instrument

参数	值
仪器名	Rigel VZ-1000
测距方法	飞行时间
回波	多回波
波长/nm	1550
最大天顶角/(°)	100
激光产品分类	一级安全激光制造
范围/m	1.5—1400
重量/kg	10

3.3 模型训练数据与验证数据

本文地面滤波模型所采用的训练数据来自 OpenGF 数据集（Qin 等，2021），该数据为超大规模机载激光雷达地面滤波数据集，覆盖 47 km²，跨越 4 个国家，包含了城市、小型城市，村庄和山地 4 大地形。

本文枝叶分离模型训练数据来自 Xi 等（2020）公开数据，共 16 个样地，包含 Lpine, Npoplar, NSpruce, RPine, SBirch, SMaple, Spine, TAspen, WSpruce 多个种类。

本文选取了 9 个红树林样地进行精度评价和结果分析。其中样地 A1 和样地 A2 来自清澜湾保护区，样地面积较大，用于单木分割结果可视化展示。样地 S1—S7 来自塔市坡里村，每个样地覆盖了不同数量的单木，由于地基激光雷达扫描的特性，每个样地的点密度也不同，表 2 展示了样地 S1—S7 的数据特征。本研究利用 CloudCompare 标注样地 S1—S7 每颗树的位置，并进行多轮的核查，用于后续精度评价。

表 2 测试样地特征

Tabel 2 Characteristics of tested samples

样地号	面积/m ²	单木数	点云密度(pts/m ²)
S1	90.4	18	35165.0
S2	153.0	41	20067.0
S3	133.8	54	4645.9
S4	110.4	39	16437.0
S5	120.4	15	7042.3
S6	193.7	23	6506.2
S7	147.9	28	6885.9

4 数据处理结果与分析

本文将所提出的单木分割框架应用到 9 个样地中进行实验。

4.1 基于 RandLA-Net 的地面滤波

本研究所采用服务器显卡配置为 GTX4090，内存 128 G。对于地面滤波模型训练，设置 batch size 为 4，每块输入点云 65536 个，体素大小为 0.06 m，设置随机梯度下降法为优化器，学习率设为 0.01，步数为 50000，采用交叉熵为损失函数。

训练过程中损失和精度如图 5，图 6 所示，模型精度在最初 10000 步得到很快提高，此时模型找到了最优下降方向，之后模型精度逐渐收敛，在训练过程中，损失和精度都存在大量抖动，这是由于在处理同一批次的样本时，样本复杂程度不一。最后损失和精度分别收敛到 0.30 和 0.92，说明 RandLA-Net 有较强拟合能力。基于上述模型对红树林数据进行地面点分类，所得可视化结果如图 9，图 10 所示。




图 5 地面滤波模型损失曲线

Fig. 5 The loss curve of ground filter model

4.2 基于 RandLA-Net 的样地场景枝叶分离

样地场景枝叶分离模型训练的超参数与地面滤波模型训练设置相同。训练过程中模型精度与损失如图 7，图 8 所示，模型在前 10000 步即取得

了较好精度，此后，模型精度收敛，训练过程中，模型的精度和损失同样出现了显著的上升和下降，最后损失收敛到0.1左右，精度收敛到0.98左右，说明模型对样本拟合度较好。




图6 地面滤波模型精度曲线
Fig. 6 The accuracy curve of ground filter model

4.3 单木分割

基于上述枝叶分离的结果进行单木分割，所得结果如图13—18所示。可以看出，本文算法分割所得单木形态较为合理。




图7 枝叶分离模型精度曲线
Fig. 7 The accuracy curve of wood-leaf segmentation model




图8 枝叶分离模型损失曲线
Fig. 8 The loss curve of wood-leaf segmentation model




图9 样地A1地面滤波结果(红色为非地面点,蓝色为地面点)
Fig. 9 Ground filter result of plot A1, the nonground points and ground points are marked by red and blue colors respectively



图10 样地A2地面滤波结果(红色为非地面点,蓝色为地面点)
Fig. 10 Ground filter result of plot A2 the nonground points and ground points are marked by red and blue colors respectively




图11 样地A1枝叶分离结果
Fig. 11 Wood-leaf segmentation result of plot A1, the wood points and leaf points are marked by brown and green colors respectively




图 12 样地 A2 枝叶分离结果

Fig. 12 Wood-leaf segmentation result of plot A2, the wood points and leaf points are marked by brown and green colors respectively



图 13 样地 A1 单木分割结果顶视图

Fig. 13 Individual tree segmentation result of plot A1 top view

图 19 展示了本文方法在样地 S1—S7 的单木位置提取结果，其中红色圆圈代表被正确检测的单木位置，叉代表所提取单木位置，星号代表参考单木的

位置。由图 19 可知基于本文所提出的方法能够较好地提取出单木，存在较少的欠分割和过分割现象。

本文精度评价方法如下 (Liang 等, 2018)。

$$\text{Completeness} = \frac{N_{\text{match}}}{N_{\text{ref}}} \quad (1)$$

$$\text{Correctness} = \frac{N_{\text{match}}}{N_{\text{extract}}} \quad (2)$$

$$\text{Accuracy} = \frac{2 \cdot N_{\text{match}}}{N_{\text{ref}} + N_{\text{extract}}} \quad (3)$$

式中, N_{match} 表示被准确提取的单木数量, N_{ref} 表示参考单木的数量, N_{extract} 表示所提取的单木数量。Completeness 表示单木提取的完整率, 衡量参考单木中有多少比例被正确提取, Correctness 表示单木提取的正确率, 衡量所提取单木中有多少比例被正确提取。Accuracy 表示单木提取精度, 是完整率和正确率的综合评判。



图 14 样地 A1 单木分割结果侧视图

Fig. 14 Individual tree segmentation result of plot A1 side view



(a) 原始数据
(a) The original data



(b) 分割结果
(b) The segmentation result

图 15 样地 A1 单木分割结果局部对比

Fig. 15 Local comparison of the segmentation results of a single tree in the sample plot A1



图 16 样地 A2 单木分割结果顶视图
Fig. 16 Individual tree segmentation result of plot A2 top view



图 17 样地 A2 单木分割结果侧视图
Fig. 17 Individual tree segmentation result of plot A2 side view


表 3 定量展示了本文方法所提取单木的准确性、完整性和精度。由表 3 可知，本文方法在不同样地所提取单木的完整性均大于 0.85，均值为 0.90，说明本文方法能提取大部分树木。最后，本文方法所得整体平均精度为 0.87，说明本文方法

具有较好的有效性和可靠性。

对于不同密度点云，本文算法均取得了较好结果。这是由于本文所计算精度为单木位置精度，单木位置由树干位置决定，因此密度对实验精度的影响主要在基于 RandLA-Net 的枝叶分离部分。RandLA-Net 会对点云进行体素化处理，体素大小为 0.06 m，通过对本研究数据的分析发现，即使是在点云密度较低的部分，树干部分点云间距约为 0.02 m，小于 0.06 m，因此点云密度对实验结果的影响可以忽略不计。为了更好地说明情况，选取 S6 样地密度计算结果和主干分割结果如图 20，图 21，可知，本文算法在不同密度区域均能较好分割单木。

本文还与另外两种经典的单木分割算法进行精度对比，分别为标记控制的分水岭算法（Chen 等，2006），和基于点云的分割算法（Li 等，2012）。所得结果如表 4 所示。

由表 4 可知，在完整率方面，除了本文所提出方法外，其余两种算法在完整率方面均小于 0.5，说明其存在严重的欠分割，这也导致其余两种方法总体精度方面大幅低于本文方法。在正确率方面，基于点云的分割方法与本文方法表现类似。本文方法所得完整率为 0.90，正确率为 0.83，说明本文方法可以在提取到更多单木的同时，保证提取位置的正确性。本文方法总体精度为 0.87，大幅高于其余两种算法。



(a) 原始数据 (a) The original data (b) 分割结果 (b) The segmentation result

图 18 样地 A2 单木分割结果局部对比
Fig. 18 Local comparison of the segmentation results of a single tree in the plot A2




图 19 本文所提出方法的单木分割结果

Fig. 19 Extracted results by the proposed method

表3 本文方法在样地S1—S7所得精度
Tabel 3 Accuracy assessment of the proposed method in plot S1—S7

样地号	完整率	正确率	精度
S1	0.89	0.72	0.80
S2	0.85	0.95	0.90
S3	0.93	0.93	0.93
S4	0.92	0.88	0.90
S5	0.87	0.72	0.79
S6	0.91	0.75	0.82
S7	0.96	0.87	0.92
均值	0.90	0.83	0.87




图20 样地S6点云在0.023 m内邻域点数,颜色偏绿代表邻域点数多,点云密度高,颜色偏蓝则相反

Fig. 20 Number of neighborhood points in the S6 sample point cloud within 0.023 m. The greener color means there are more neighborhood points and higher point cloud density. The opposite is true for the bluer color




图21 样地S6主干分割结果
Fig.21 Main stem segmentation result of plot S6

为了展示3种方法在不同样地中的表现,本文在7个样地中分别计算了完整率、正确率和精度,如图13,图14,图15所示。如图22所示,本文方法在7个样地中完整率要大幅高于其余两种算法,

且所得完整率差异较小,均要大于0.85,说明本文方法能够在7个样地中均能较为完整地检测出单木,这对于生物量计算等研究有重要意义。在7个样地中,基于CHM的泼水算法都存在严重的欠分割现象,这可能是树木较为密集,树冠不规则导致。如图23所示,在7个样地中,本文方法在S2, S5, S6, S7样地正确率均大于其余两种方法。如图24所示,本文算法在7个样地中精度均要高于其余两种算法,且各个样地的精度差异较小,说明本文方法不仅能有效检测出单木,且在不同样地下具有较好的稳定性。

表4 3种算法样地平均精度比较
Tabel 4 Average accuracy comparison of three methods

算法	完整率	正确率	精度
Chen等(2006)	0.10	0.55	0.15
Li等(2012)	0.49	0.77	0.58
本文方法	0.90	0.83	0.87

注:加粗字体表示最优值。




图22 3种方法完整率对比
Fig. 22 Completeness of three methods




图23 3种方法正确率对比
Fig. 23 Correctness of three methods




图24 3种方法精度对比

Fig. 24 Accuracy of three methods

5 结 论

本文提出了一种适用于植被密集与枝干错综复杂的红树林区域的单木分割框架，其包含3个阶段。在地面滤波阶段，为了解决传统算法难以适应于红树林区域地形复杂，地表植被密集的问题，本文引入了点云深度学习框架RandLA-Net，在大量数据驱动下，深入学习复杂的地表特征。在枝叶分离阶段，本文同样使用了RandLA-Net框架进行了样地场景枝叶分离的实验，结果显示该网络能较好地提取树木主干，在复杂场景下的热带红树林单木分割中体现出较好的潜力。最后，本文提出了一种新的基于树顶点多约束的分割方法，能够有效对热带红树林进行单木分割。为了进行精度分析，本研究标注了7个具有不同数据特征的样地。实验结果表明，相比于其他算法，本文方法取得了最高精度，且尽管各个样地特性不同，本文方法总体精度均超过0.8，说明了本文方法的有效性和鲁棒性。然而，本文方法依然存在一些不足之处。基于RandLA-Net的地面滤波模型对不同密度点云不能做到自适应，需要调整参数，且模型的泛化性有待提高，对于机载点云和地基点云需要分别进行训练才能达到较高精度。基于RandLA-Net的样地场景枝叶分离，模型能较好提取出树木主干，但对于树枝的提取精细化程度有待提高，且本文缺乏对枝叶分离结果的定量精度评价，在后续研究中争取改进模型，进行不同数据源下的实验，并定量评价精度。基于树顶点的单木分割算法，由于基于种子点以一定半径进行圆柱搜索可能无法覆盖到所有点云，因此需要进行一定的后处理操作，算法的适应性和运算效率

有待提高。在后续研究中，本文将针对上述问题做更加细致深入的研究。

志 谢 此次野外实验的数据得到了贾明明老师和张鸿生老师的支持，在此表示衷心的感谢！

参考文献 (References)

- Ahlswede S, Schulz C, Gava C, Helber P, Bischke B, Förster M, Arias F, Hees J, Demir B and Kleinschmit B. 2023. *TreeSatAI Benchmark Archive: a multi-sensor, multi-label dataset for tree species classification in remote sensing*. Earth System Science Data, 15(2): 681-695 [DOI: 10.5194/essd-15-681-2023]
- Boyd D S, Foody G M and Ripple W J. 2002. Evaluation of approaches for forest cover estimation in the Pacific Northwest, USA, using remote sensing. Applied Geography, 22(4): 375-392 [DOI: 10.1016/S0143-6228(02)00048-6]
- Chen Q, Baldocchi D, Gong P and Kelly M. 2006. Isolating individual trees in a savanna woodland using small footprint lidar data. Photogrammetric Engineering and Remote Sensing, 72(8): 923-932 [DOI: 10.14358/PERS.72.8.923]
- Chen X X, Jiang K, Zhu Y S, Wang X J and Yun T. 2021. Individual tree crown segmentation directly from UAV-borne LiDAR data using the PointNet of deep learning. Forests, 12(2): 131 [DOI: 10.3390/f12020131]
- Duke N C, Meynecke J O, Dittmann S, Ellison A M, Anger K, Berger U, Cannicci S, Diele K, Ewel K C, Field C D, Koedam N, Lee S Y, Marchand C, Nordhaus I and Dahdouh-Guebas F. 2007. A world without mangroves? Science, 317(5834): 41-42 [DOI: 10.1126/science.317.5834.41b]
- Gao G L, Xin Z B, Ding G D, Li C C, Zhang J Y, Liang W J, An Y, He Y, Xiao M and Li W Y. 2013. Forest health studies based on remote sensing: a review. Acta Ecologica Sinica, 33(6): 1675-1689 (高广磊, 信忠保, 丁国栋, 李丛丛, 张佳音, 梁文俊, 安云, 贺宇, 肖萌, 李文叶. 2013. 基于遥感技术的森林健康研究综述. 生态学报, 33(6): 1675-1689) [DOI: 10.5846/stxb201112011838]
- Guo X X, Wang L, Tian J Y, Yin D M, Shi C and Nie S. 2018. Vegetation horizontal occlusion index (VHOI) from TLS and UAV image to better measure mangrove LAI. Remote Sensing, 10(11): 1739 [DOI: 10.3390/rs10111739]
- Hu Q Y, Yang B, Xie L H, Rosa S, Guo Y L, Wang Z H, Trigoni N and Markham A. 2020. RandLA-Net: efficient semantic segmentation of large-scale point clouds//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE: 11105-11114 [DOI: 10.1109/CVPR42600.2020.01112]
- Hu X Y and Yuan Y. 2016. Deep-learning-based classification for DTM extraction from ALS point cloud. Remote Sensing, 8(9): 730 [DOI: 10.3390/rs8090730]
- Hyypä J, Kelle O, Lehtikoinen M and Inkinen M. 2001. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. IEEE Transactions on

- Geoscience and Remote Sensing, 39(5): 969-975 [DOI: 10.1109/36.921414]
- Jahromi A B, Zoj M J V, Mohammadzadeh A and Sadeghian S. 2011. A novel filtering algorithm for bare-earth extraction from airborne laser scanning data using an artificial neural network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(4): 836-843 [DOI: 10.1109/JSTARS.2011.2132793]
- Jia M M, Wang Z M, Mao D H, Huang C L and Lu C Y. 2021. Spatial-temporal changes of China's mangrove forests over the past 50 years: an analysis towards the Sustainable Development Goals (SDGs). *Chinese Science Bulletin*, 66(30): 3886-3901 (贾明明, 王宗明, 毛德华, 黄春林, 路春燕. 2021. 面向可持续发展目标的中国红树林近 50 年变化分析. *科学通报*, 66(30): 3886-3901) [DOI: 10.1360/TB-2020-1412]
- Kwak D A, Lee W K, Lee J H, Biging G S and Gong P. 2007. Detection of individual trees and estimation of tree height using LiDAR data. *Journal of Forest Research*, 12(6): 425-434 [DOI: 10.1007/s10310-007-0041-9]
- Li W K, Guo Q H, Jakubowski M K and Kelly M. 2012. A new method for segmenting individual trees from the lidar point cloud. *Photogrammetric Engineering and Remote Sensing*, 78(1): 75-84 [DOI: 10.14358/PERS.78.1.75]
- Liang X L, Hyypä J, Kaartinen H, Lehtomäki M, Pyörälä J, Pfeifer N, Holopainen M, Brolly G, Francesco P, Hackenberg J, Huang H B, Jo H W, Katoh M, Liu L X, Mokroš M, Morel J, Olofsson K, Poveda-Lopez J, Trochta J, Wang D, Wang J H, Xi Z X, Yang B S, Zheng G, Kankare V, Luoma V, Yu X W, Chen L, Vastaranta M, Saarinen N and Wang Y S. 2018. International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144: 137-179 [DOI: 10.1016/j.isprsjprs.2018.06.021]
- Liao J J, Zhen J N, Zhang L and Metternicht G. 2019. Understanding dynamics of mangrove forest on protected areas of Hainan Island, China: 30 years of evidence from remote sensing. *Sustainability*, 11(19): 5356 [DOI: 10.3390/su11195356]
- Lu X C, Guo Q H, Li W K and Flanagan J. 2014. A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94: 1-12 [DOI: 10.1016/j.isprsjprs.2014.03.014]
- Luo Z P, Zhang Z Y, Li W, Chen Y P, Wang C, Nurunnabi A A M and Li J. 2022. Detection of individual trees in UAV LiDAR point clouds using a deep learning framework based on multichannel representation. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5701715 [DOI: 10.1109/TGRS.2021.3130725]
- McRoberts R E, Næsset E and Gobakken T. 2013. Inference for lidar-assisted estimation of forest growing stock volume. *Remote Sensing of Environment*, 128: 268-275 [DOI: 10.1016/j.rse.2012.10.007]
- Morsdorf F, Nichol C, Malthus T and Woodhouse I H. 2009. Assessing forest structural and physiological information content of multi-spectral LiDAR waveforms by radiative transfer modelling. *Remote Sensing of Environment*, 113(10): 2152-2163 [DOI: 10.1016/j.rse.2009.05.019]
- Popescu S C, Wynne R H and Nelson R F. 2003. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Canadian Journal of Remote Sensing*, 29(5): 564-577 [DOI: 10.5589/m03-027]
- Pouliot D and King D. 2005. Approaches for optimal automated individual tree crown detection in regenerating coniferous forests. *Canadian Journal of Remote Sensing*, 31(3): 255-267 [DOI: 10.5589/m05-011]
- Qi C R, Su H, Mo K C and Guibas L J. 2017. PointNet: deep learning on point sets for 3D classification and segmentation//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE: 77-85 [DOI: 10.1109/CVPR.2017.16]
- Qin N N, Tan W K, Ma L F, Zhang D D and Li J. 2021. OpenGF: an ultra-large-scale ground filtering dataset built upon open ALS point clouds around the world//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Nashville: IEEE: 1082-1091 [DOI: 10.1109/CVPRW53098.2021.00119]
- Reitberger J, Schnörr C L, Krzystek P and Stilla U. 2009. 3D segmentation of single trees exploiting full waveform LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(6): 561-574 [DOI: 10.1016/j.isprsjprs.2009.04.002]
- Ren S Q, He K M, Girshick R and Sun J. 2015. Faster R-CNN: towards real-time object detection with region proposal networks//*Proceedings of the 29th International Conference on Neural Information Processing Systems*. Montreal: MIT Press: 91-99
- Strimbu V F and Strimbu B M. 2015. A graph-based segmentation algorithm for tree crown extraction using airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104: 30-43 [DOI: 10.1016/j.isprsjprs.2015.01.018]
- Wang J M, Chen X X, Cao L, An F, Chen B Q, Xue L F and Yun T. 2019. Individual rubber tree segmentation based on ground-based LiDAR data and faster R-CNN of deep learning. *Forests*, 10(9): 793 [DOI: 10.3390/f10090793]
- Windrim L and Bryson M. 2020. Detection, segmentation, and model fitting of individual tree stems from airborne laser scanning of forests using deep learning. *Remote Sensing*, 12(9): 1469 [DOI: 10.3390/rs12091469]
- Xi Z X, Hopkinson C, Rood S B and Peddle D R. 2020. See the forest and the trees: effective machine and deep learning algorithms for wood filtering and tree species classification from terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168: 1-16 [DOI: 10.1016/j.isprsjprs.2020.08.001]

Individual tree segmentation of terrestrial tropical mangrove forest point clouds based on multiple constraints at tree tops

LIU Wangjun^{1,2,3}, CHEN Yiping¹, WANG Chaolei¹, ZHANG Wuming¹, WANG Cheng^{2,3}

1. School of Geospatial Engineering and Science, Sun Yat-Sen University, Zhuhai 519082, China;

2. Key Laboratory of Digital Earth Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

3. College of Resources and Environment, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: Tropical mangroves are one of the most productive and biodiverse forest resources but face several challenges such as monoculture planting structures, low ecosystem quality, low survival rates of planted mangroves, and threats from extreme weather and pests. Conducting surveys on mangrove forest resources provides essential data for the scientific management and conservation of these resources. Accurate segmentation of individual trees is a prerequisite for the inventory of such forest resources. Terrestrial Laser Scanning (TLS) can provide massive, high-precision, and high-resolution 3D point cloud data. However, the point cloud data are characterized by irregularities, varying densities due to distance, and incompleteness due to occlusions. Furthermore, the mangrove scene is complex with interlaced large and small trees and tree occlusions, making precise individual tree segmentation a considerable challenge. Traditional methods such as local maximum detection based on Canopy Height Models (CHM), have demonstrated good performance in simple plot scenarios. However, in the complex canopy interwoven environments of mangroves, where the upper canopy features are weak, these methods are less effective. Currently, there is a lack of research on individual tree segmentation algorithms for mangroves based on TLS point clouds. To address these issues, we aim to propose an individual tree segmentation algorithm applicable for complex mangrove scenes. This study innovatively combines deep learning and traditional algorithms to propose a high-precision individual tree segmentation framework for TLS point clouds in complex mangrove scenes. The framework initially employs the deep learning network RandLA-Net for ground filtering and wood-leaf separation. Subsequently, mangrove main stems are segmented using a connected component segmentation method. Finally, individual tree segmentation is achieved through the multiple tree tops constraint module. To assess the accuracy of the algorithm, we use three measures: completeness, correctness, and accuracy. We also conduct a comparative analysis with two classical algorithms. The experimental results demonstrate that the completeness of the proposed method across different mangrove plots is greater than 0.85, with an average of 0.90; the correctness of the proposed method is greater than the two classic algorithms in four plots; the mean accuracy of the proposed method in different sample plots reaches 0.87, which is significantly higher than the two classic algorithms, thus proving the effectiveness and reliability of our method. This paper proposes an individual tree segmentation framework for TLS point clouds in complex mangrove scenes. Seven sample plots with various data characteristics were annotated to assess accuracy. The experimental results show that, compared to other algorithms, the proposed method achieved the highest accuracy. Despite the differing characteristics of the sample plots, the overall accuracy of the proposed method exceeded 0.8, demonstrating its effectiveness and robustness.

Key words: tropical mangroves, terrestrial laser scanning, point cloud, individual tree segmentation, deep learning

Supported by National Natural Science Foundation of China (No. 42371343)