

基于激光雷达数据的森林生物量估测研究

陆灯盛^{1,2}, 蒋先蝶^{1,2,3}, 李云鹤^{1,2}, 王若琦^{1,2}, 李桂英^{1,2}

1. 福建师范大学 湿润亚热带生态地理过程教育部重点实验室, 福州 350117;

2. 福建师范大学 地理研究所, 福州 350117;

3. 福建师范大学 地理学博士后流动站, 福州 350117

摘要: 激光雷达已成为森林生物量估测制图的重要数据源。过去30余年已有大量研究,但至今仍未进行系统性总结。本文总结了不同平台激光雷达数据(近地面、机载、星载)在单木、林分及景观尺度森林生物量估测研究现状及存在问题,探讨了激光雷达与其他数据(如光学、微波雷达、辅助数据等)结合对估测精度的提升作用;梳理了森林生物量估测建模方法的研究现状,分析了估测模型的不确定性来源及优化策略,探讨了模型在时间与空间尺度上的可迁移性,进而讨论了构建普适性森林生物量估测模型的必要性。本文的系统性总结有助于相关研究人员深入了解激光雷达技术在森林生物量估测研究现状及挑战,满足应用各平台激光雷达数据提高各尺度森林生物量估测精度的诉求。

关键词: 森林生物量, 近地面激光雷达, 机载激光雷达, 星载激光雷达, 多源数据, 建模方法, 不确定性, 模型可迁移性, 模型普适性

中图分类号: TP701/P2

引用格式: 陆灯盛, 蒋先蝶, 李云鹤, 王若琦, 李桂英. 2025. 基于激光雷达数据的森林生物量估测研究. 遥感学报, 29(6): 2035-2064

Lu D S, Jiang X D, Li Y H, Wang R Q and Li G Y. 2025. Forest biomass estimation with LiDAR data. National Remote Sensing Bulletin, 29(6): 2035-2064 [DOI: 10.11834/jrs.20255022]

1 引言

森林作为陆地生态系统中最大的碳汇,对缓解气候变化、维持生态平衡以及促进可持续发展具有重要意义(Walker等, 2022)。及时准确地监测森林生物量的时空变化,可为评估森林生产力,森林资源管理、生态恢复及碳交易等提供数据支持(Erb等, 2018)。传统的森林生物量计算方法是基于样地调查和抽样理论,该方法耗时费力,难以提供空间连续的森林生物量分布(Barrett等, 2016; Zeng等, 2023)。20世纪70年代初卫星遥感兴起,尤其是80年代中期以Landsat和SPOT为代表,卫星遥感数据以其覆盖范围广、数据更新快、时空连续性强等优势,成为森林资源调查和监测的主要数据源(Lu, 2006; Lu等, 2016; Araza等, 2022)。

基于遥感技术的森林生物量估测工作主要针对地上生物量展开。早期研究主要利用光学遥感数据如Landsat (Lu, 2006)。近年来,不断提升的空间、光谱、时间和辐射分辨率,以及各种传感器遥感数据的不断涌现为森林生物量估测建模提供了丰富的数据源(Barrett等, 2016; Lu等, 2016; Xiao等, 2019)。相比仅可获取地表反射特性的光学数据,微波雷达技术以其森林冠层穿透能力与所捕获的森林结构特征信息丰富度而受到关注(David等, 2022)。然而,光学和雷达数据主要反映森林冠层的水平结构特征,缺乏与生物量直接相关的垂直结构信息。在生物量较大的茂密森林区域,二者均存在信号饱和问题,即生物量达到一定数值时,光学或雷达数据难以有效反映林分生物量变化(Lu, 2005; Le Toan等, 2011; Zhao等, 2016a)。此外,地形、大气条件和植被

收稿日期: 2025-01-10; 预印本: 2025-02-15

基金项目: 国家自然科学基金(编号: 32171787)

第一作者简介: 陆灯盛,研究方向为植被定量遥感。E-mail: ludengsheng@fjnu.edu.cn

通信作者简介: 李桂英,研究方向为林业遥感。E-mail: liguiying@fjnu.edu.cn

物候等因素影响光学或雷达获取的辐射数据，导致基于这些数据建立的生物量模型估测精度低、外延性差，难以应用于森林生物量时空精确估测与制图（Lu等，2016；Nguyen等，2019）。而激光雷达数据具有捕捉森林垂直结构特征（如树高）的能力（Dong和Chen，2018；Coops等，2021），有效解决了光学和雷达数据信号饱和问题，成为森林资源调查的最佳数据源（李增元等，2016；郭庆华等，2018；Lu和Jiang，2024）。

激光雷达技术在林业中的应用日益广泛（Guo等，2021；Lu和Jiang，2024）。利用不同激光雷达平台（近地面、机载、卫星等）的森林生物量估测研究已取得了显著进展。本文围绕激光雷达技术在森林生物量估测研究现状展开论述。首先介绍不同平台激光雷达数据在生物量估测中的研究现状，分析其在单木、林分及景观尺度各自的特点；其次，探讨激光雷达与其它遥感数据联合（如光学、雷达、辅助数据等）在生物量估测中的精度提升作用；而后，梳理当前生物量估测建模方法研究现状及其发展趋势，剖析生物量估测模型不确定性，总结建模过程优化策略，评估模型在时间和空间尺度上的可迁移性，阐明构建森林

生物量普适性估测模型的必要性。本文的系统性总结，可帮助相关研究人员更好地了解激光雷达技术在森林生物量估测制图研究中的现状及发展趋势，为深化不同平台激光雷达技术在林业中的应用提供重要参考。

2 不同平台激光雷达数据的森林生物量估测研究

激光雷达数据可从地面、移动车辆、无人机、航空飞机和卫星等不同平台获取，为森林生物量估测提供多种技术手段（Guo等，2021）。地面和移动车辆激光雷达因其非常高的点云密度，通常用于单木参数如胸径、树高和冠幅的提取，但由于数据采集成本高、数据量庞大且处理困难，多限于样地尺度（Xu等，2021）。机载激光雷达数据能够获取森林三维结构，常用于林分尺度森林生物量估算（Lu和Jiang，2024）。星载激光雷达数据虽然本身无法提供全覆盖的森林生物量估测（庞勇等，2019；Duncanson等，2020），但以其获取全球尺度条带光斑的地表及目标三维信息的能力，为大范围的森林生物量估测提供了新的机遇。表1简要地总结了不同平台激光雷达数据的特点。

表1 不同平台激光雷达数据的特点

Table 1 Characteristics of LiDAR data from different platforms

平台类型	特点描述	优缺点
近地面	地基激光扫描仪 以静态扫描方式获取极高点云密度的数据,但扫描范围有限,适用于单木精细结构分析	数据定位精度高,可获得精细树木结构。单站扫描存在遮挡问题,而多站扫描存在站间数据配准问题;数据采集处理耗时,缺乏大规模采集数据的能力;受冠层密度的影响,冠顶点云易缺失
	移动(手持、背包、车载激光扫描) 以移动扫描方式,动态采集数据范围更大,适用于快速提取树木精细结构	数据采集过程灵活、高效,适合地形较平坦、林下植被较少的森林(如人工林),可精细刻画林分结构。数据定位精度相对较低;受冠层密度的影响,冠顶点云易缺失
机载	无人机激光雷达 低空飞行,成本低、操作简单,特别适用于小规模森林生物量精细监测	数据采集灵活,获取的点云密度较高,但覆盖范围相对有限;受冠层密度影响,林下植被点云数据较少,难以有效刻画林下植被特征
	有人机激光雷达 高空飞行,操作成本较高,需要专业的飞行设备和团队来实施飞行任务	数据采集灵活,可实现林分尺度全覆盖,但点云密度较低;冠层下点云缺失;受成本限制,难以实现大规模时间连续的观测
星载	卫星如ICESat-1/2;空间站 GEDI 按照数据形式分为:全波形(返回完整波形,如GLAS和GEDI)和光子计数(返回离散光子,如ATLAS)激光雷达	可获取全球尺度的冠层高度数据;光斑直径较大,林下地形和树木空间结构等信息缺失;无法实现区域全覆盖;受植被覆盖度及地形影响大,提取的冠层高度精度较低

2.1 近地面激光雷达数据的单木生物量估测

近地面激光雷达技术通过自下而上扫描方法，获取高点云密度数据，提供丰富的林分结构信息，

被认为是提取单木参数和减少现场工作的重要数据来源（Liang等，2018；Wang等，2019a）。近地面激光雷达数据通常用于单木参数如胸径和树高的

提取，然后利用异速生长方程计算单木生物量（Brede 等，2022），激光雷达生物量指数（LBI）（Du 等，2023）及单木点云体素（Huo 和 Zhang，2019）也用于单木生物量的计算。根据搭载平台的差异，近地面激光雷达包括地基、手持、背包等（Xu 等，2021；Fekry 等，2022）。表 2 总结了近地面激光雷达数据的特点及应用现状。

表 2 近地面激光雷达数据特点及应用现状

Table 2 Characteristics of close-ground LiDAR data and their application situations

获取方法	优缺点	精度	关键文献
地基	单木参数估测精度高,常用于精细结构分析,但数据量大,林下植被遮挡严重	北方森林单木参数提取: 相对均方根误差(rRMSE):胸径 5%—15%; 树高 10%—30%;单木生物量 15%—45%	Liang 等,2018; Wang 等,2021
手持、背包等	数据采集灵活性高,单木参数估测精度略低于地基,林下植被遮挡严重	北方森林单木参数提取: rRMSE:胸径 10%—35%;树高 20%—45%; 单木生物量 20%—80%	Liang 等,2018;
林下无人机	数据采集效率高,但密林中自主飞行存在挑战。数据质量相对地基激光雷达低	亚热带单层森林单木参数(胸径)提取: 均方根误差(RMSE):5.13 cm; rRMSE:22.01% 北方针叶林的单木参数提取: RMSE:胸径 3.76 cm;rRMSE:胸径 15.23%	Liang 等,2024 Wang 等,2021
近地面和无人机激光雷达数据的融合	对于树高、材积估测精度有所改进;受限于小范围数据采集,单木生物量估测的过程中存在误差累计	亚热带水杉、杨树单木参数提取: RMSE(rRMSE):胸径 1.5—1.82 cm(4.84%—5.77%);树高 1.10—1.19 m(4.58%—3.76%); 材积 0.023—0.049 m ³ (17.06%—19.07%) 温带针叶林单木参数提取: rRMSE:胸径 13.70%—14.82%; 树高 2.18%—4.14%;冠幅 9.24%—12.94% 亚热带杉木人工林单木参数提取: rRMSE:胸径 8.4%;单木蓄积量 17.4%	Fekry 等,2022 Qi 等,2022 Li 等,2024a

2.1.1 地基激光扫描

地基激光扫描通过静态采集方式扫描数据，提供细致且高精度的树木形态特征，如树干、枝干、树冠、叶片等细节，适合单木三维结构的精细分析（Wang 等，2020）。由于树木遮挡效应，需要多站扫描来补偿单站扫描的不足，增加了数据采集的时间成本。其捕捉的数据点云密度高，数据量庞大，数据采集后需要进行多站点云的配准和拼接处理。从地基激光扫描数据精确提取单木参数（如胸径和树高），利用异速生长方程计算单株生物量。该方法可以有效提高生物量样本数据的质量，同时减少外业工作量（Brede 等，2022）。然而异速生长方程具有地域依赖性，不当使用生长方程有可能导致较大的生物量计算误差。

为减少传统异速生长方程所产生的误差，考虑对单木点云进行三维重建，结合对应树种的木材密度将体积转换为生物量估计值（Demol 等，2022）。该方法可分为两类：（1）体素技术，即将

单木点云分割为适当大小的立方体（体素），根据填充体素的分数估计单木材积；（2）构建树木定量结构模型 QSM（Quantitative Structure Model）：QSM 是一种按层次顺序通过几何单元描述树木的模型，可用于单木生物量估测（Hackenberg 等，2015；Du 等，2019；Fan 等，2020）。然而，要获取高质量树拓扑结构模型，需要先验知识或手动参与（Martin-Ducup 等，2021）。同时，受算法的复杂性和林内树木遮挡等因素的限制，需要进一步探索其重建方法来减少误差（Xie 等，2018）。通过分析三维重建的单木点云数据，根据生物量与冠高参数的关系，构建基于物理特性的单木生物量估测指数，精度接近于基于胸径和树高的二元异速生长方程的估测结果，尤其是针叶林，rRMSE 可低于 16%（Wang 等，2021）。

2.1.2 便携式激光雷达扫描

为弥补地基激光扫描数据中林下植被遮挡和

数据配准的不足,轻量级的便携式激光雷达扫描设备(如背包和手持激光扫描仪)逐渐得以广泛应用。这些设备在数据采集过程中的位置信息依赖于内置IMU(惯性测量单元)或GPS等定位系统,操作人员携带扫描仪获得高保真点云数据(Fekry等,2022)。由于便携式激光雷达平台的灵活采集模式,定位精度低于地基激光扫描,获取的点云分布较分散,且存在噪声、重影等现象,影响后续参数提取(尤其是胸径)及生物量的计算(Duanmu和Xing,2020)。在林下植被相对简单的林分中,地基和便携式激光扫描数据的定位精度差异对树木检测和胸径提取精度影响较低(Cabo等,2018),而在林下植被复杂的林分场景中,基于地基激光扫描和便携式激光雷达扫描数据的单木生物量的相对均方根误差(rRMSE)则相差30%左右(Liang等,2018;Li等,2024a)。因此,在复杂林分状况下,需要进一步研究高精度的单木分割以及单木参数提取算法。

2.1.3 林下无人机激光扫描

因近地面激光雷达数据需调查人员参与采集,近年来有研究尝试采用林下无人机激光扫描仪获取数据的可行性。在林分简单的人工林或城市森林,当轨迹加密时,点云的几何精度和完整性显著提高,能得到与基于地面的激光雷达数据类似的树干描绘能力(Liang等,2024)。然而,这样的扫描方式更适用于林分简单且相对开阔的北方森林。受到扫描仪性能和全球导航卫星系统(GNSS)和IMU轨迹的限制(Wang等,2021),林下无人机数据的几何精度尚未达到地基激光扫描的水平。后续需探讨无人机自主路线规划以及点云数据几何精度提高方法。

2.1.4 近地面和无人机激光雷达数据的融合

地面激光雷达数据通过自下而上扫描方法,提供丰富的林分三维结构信息(Liang等,2018),但存在树冠顶部点云缺失现象,致使树高低估(Wang等,2019b;Jurjević等,2020);无人机激光雷达采用自上而下扫描的方法,精准有效获取森林高密度冠层点云数据。联合无人机和地面激光扫描数据,可获得完整树木三维结构点云。在树木三维建模工作中,融合数据可提升树枝体积估测精度(Terryn等,2022)。对于高冠层覆盖下、

复杂林分场景中的单木,融合数据相较于单一数据源可得到更优的单木参数提取结果(Jurjević等,2020;Qi等,2022)。比如,融合无人机激光雷达和地基激光雷达比单一使用地基激光雷达数据获取的亚热带森林(包括杨树和水杉)树高、树体积和冠体积,rRMSE分别显著降低了9.01%、5.28%和18.61%(Fekry等,2022)。

在多平台激光雷达数据融合过程中,点云数据配准是提取单木参数的关键步骤。常用配准流程包含两个阶段,即预先对齐数据的粗配准(如快速点特征直方图、随机样本共识算法等)和细化配准参数的精配准(如迭代最近点等)(Zhang等,2021a;Dai等,2022;Zhao等,2023b)。受重叠点缺乏及森林的复杂性和数据源扫描视点差异的影响,直接基于点云匹配的传统方法难以准确匹配无人机和地基激光雷达数据(Guan等,2020),因此单木属性如树干位置、树高和树冠的相似性常作为特征应用于两种数据的粗配准。在山区森林中,该类算法的配准精度可达到0.5 m以内(Liu等,2021b)。但在复杂的森林中,单木属性较大的不确定性严重影响数据配准精度。曾有研究尝试在亚热带森林中改进现有配准方法,并在不同林分结构样地中进行验证,得到相似的精度(Dai等,2022;Chen等,2024a),其关键在于找到更可靠且充足的匹配点,如通过对树干点云分层聚类提取特征,以抵消无人机激光雷达在茂密森林的遮挡下获取有限树干点的影响(Chen等,2024a)。Dai等(2022)不依赖于单木属性,而在枝叶分类的基础上通过使用树木响应指示器直接检测两种点云数据的语义引导关键点用于点云配准。此外,无人机激光雷达数据也存在航线间点云配准的问题(Brede等,2019)。近地面激光雷达数据具有更高的点云密度和定位精度,可以从中获取更精确的平面特征,为改善无人机激光雷达扫描航线间的配准提供参考点。

尽管在近地面和无人机激光雷达数据的配准和单木生物量的估测方面已有许多研究,但还需要进一步明确数据融合算法、单木自动分割及枝叶分类算法对于单木生物量估测的影响,探讨融合激光雷达数据在不同林分结构获取单木参数的适用性;尤其需要提高复杂林分的单木分割和参数提取性能,以及复杂林分结构的单木三维重建性能。目前,在高度复杂森林中,即时定位与点

云配准存在较大的挑战。实际上，无人机激光雷达并不是填补近地面激光扫描中由于遮挡造成的树冠点云缺失的唯一选择。计算机图形学领域正尝试整合语义信息来进行图形重建并填充遮挡，该技术有望应用于近地面激光点云，从而最大限度填充树冠顶部点云数据的缺失（Calders 等，2020）。

2.2 机载激光雷达数据的林分(样地)尺度森林生物量估测

机载激光雷达能够自上而下穿透树冠，提供从冠层到地面的完整垂直结构信息，弥补了地面

激光雷达仅能捕捉近地面林分结构的局限，为准确反映森林结构特征提供了更丰富的数据来源。机载激光雷达可覆盖较大区域，数据获取效率高，尤其适合于复杂地形条件下的林分尺度森林生物量估测。Lu 和 Jiang（2024）总结了基于机载激光雷达数据进行森林生物量估测的一般过程，包括数据准备（如样地和机载激光雷达数据的获取和预处理）、变量的提取和筛选、建模方法的选择、精度评价及生物量反演。根据飞行平台的不同，机载激光雷达可分为低空（无人机）和高空（有人机）。表3总结了基于机载激光雷达数据的林分（样地）尺度森林生物量估测方法。

表3 基于机载激光雷达数据的林分(样地)尺度森林生物量估测
Table 3 Forest biomass estimation at stand (plot) scale based on airborne LiDAR data

估测方法	优缺点	参数提取精度	关键文献
单木汇总的方法:样地内所有单木的生物量进行汇总以获取总生物量	不依赖于样地调查数据,模型可迁移性强;精度受单木参数提取精度和生物量估测精度影响	中国东北温带落叶松生物量: $R^2=0.58-0.83$; RMSE=26.95—33.13 t/ha; rRMSE=21.21—26.00%	Du 等,2023
		广西亚热带桉树生物量: $R^2=0.85$, RMSE=24.82 t/ha,rRMSE=30.36%	
基于面积的估测方法:将激光雷达变量与样地实测值结合,建立林分尺度生物量估测模型	方法简单,预测速度快;估测精度受森林类型及建模方法的影响,模型空间可迁移性差	芬兰南部北方森林蓄积量:RMSE=53.8 m ³ /ha; rRMSE=28.6%	Vastaranta 等,2012
		巴西亚马逊森林生物量: $R^2=0.70$, RMSE=41.7t/ha	Longo 等,2016
		江苏平原银杏生物量: $R^2=0.94$, RMSE=8.36 t/ha	Liu 等,2018
		甘肃大堰口针叶林生物量: $R^2=0.70$, RMSE=14.71 t/ha	Nie 等,2017
基于点云数据采用机器学习的估测方法:直接在模型中输入所有点云数据预测生物量	基于点云结构信息提取的变量,利用机器学习构建估测模型,鲁棒性强,但需要大量样本训练模型	广西亚热带阔叶林生物量: $R^2=0.49$, RMSE=38.77t/ha;rRMSE=23.47%	Jiang 等,2020a
		丹麦森林生物量: $R^2=0.84$, RMSE=41.1 t/ha	Oehmcke 等,2024

2.2.1 无人机激光雷达技术

得益于无人机技术和小型化激光雷达传感器的快速发展，无人机激光雷达技术因其操作灵活和获取数据的高效便利，特别适用于小规模或特定区域（如人员难以进入的林区）的精细生物量监测。无人机激光雷达通常在低空飞行，采集的数据点云密度高，可以捕捉到森林的细微结构，如单株树木的高度和冠层形态（王伟伟 等，2022）。因此，可以直接使用点云数据提取多种变量，如冠层高度、冠层密度等特征，构建单木生

物量估测模型，进而以累加的方式获取林分尺度的森林生物量（Vastaranta 等，2012；Du 等，2023）。单木生物量估测算法可以基于点云或冠层高度模型 CHM（Canopy height model）数据（Goldbergs 等，2018；Liu 等，2021b）。基于点云数据的方法，如图分割算法、均值漂移算法和点云分割算法（Li 等，2012；Williams 等，2020；Yan 等，2020），可提供丰富的三维结构信息，但对计算资源的需求较高（Aubry-Kientz 等，2019）。采用基于 CHM 数据的标记控制分水岭算法可快速高效分

离单木, 但CHM主要捕获森林最大高度信息, 缺乏详细的垂直结构特征, 存在缺失冠层以下低矮植被信息的可能性 (Goldbergs等, 2018)。由于机载激光雷达数据难以获取单木树干信息 (如胸径), 给准确估测单木生物量带来了挑战 (Xu等, 2021)。因此, 单木生物量估算方法主要通过估测相关单木结构变量, 或直接提取点云和波形特征来构建生物量估测模型 (Bruggisser等, 2020; Sun等, 2022; Zhen等, 2022)。Du等 (2023) 基于激光雷达提取树冠高度变量建立激光雷达生物量指数 LBI (Lidar biomass index), 在单木尺度上解释了 88%—95% 的方差; 当汇总至样地尺度, 其 rRMSE 比使用基于面积的估测方法建立回归模型降低了 2.07%—8.33%。

2.2.2 高空机载激光雷达

相比覆盖范围有限的无人机激光雷达, 搭载在有人机上的高空激光雷达能够在较高的飞行高度 (几百米至几千米) 进行区域甚至国家尺度 (如林业发达的北欧国家丹麦、瑞典、挪威、芬兰等) 的激光雷达数据采集, 进而对森林生物量进行估算 (Ene等, 2016; Kotivuori等, 2018; Stereńczak等, 2020)。虽然高空飞行采集的点云密度不如无人机激光雷达高, 但依然能够获取森林的主要结构特征, 如平均树高、冠层高度分布等。由于点云密度较低, 通常采用基于面积的方法从CHM提取变量作为生物量估测的主要指标 (Dong和Chen, 2018; 郭庆华等, 2018)。基于CHM衍生的变量对飞行条件和传感器设置不敏感 (Roussel等, 2017), 并且CHM仅关注冠层表面高度。因此, 相较于点云衍生变量, CHM类型变量处理速度更快, 但不可避免地会遗漏冠层内部的结构变化。一些研究表明, 基于点云和基于CHM提取的变量对森林参数的预测性能差异不大 (Lu等, 2012)。

高空激光雷达的劣势在于其操作成本较高, 通常需要专业的飞行设备和团队来实施飞行任务。点云密度较低的数据可能会导致地面点缺失, 难以在复杂地形和高植被覆盖度下获取精确的森林高度。综合现有文献发现对于平坦地形、简单林分 (如杨树、银杏), R^2 为 0.71—0.94, rRMSE 为 12.67%—14.50% (Liu等, 2018; Wang等, 2024a); 但对于复杂地形的林分 (阔叶混交), R^2 为 0.5—0.94, rRMSE 为 23.23%—29.54%

(Longo等, 2016; Jiang等, 2020a)。不同于基于点云或者CHM的统计变量, 直接基于点云数据使用深度学习方法可以充分利用点云结构信息, 提高生物量估测精度 (Oehmcke等, 2024)。然而, 该方式所需的样本数量过多, 点云数据的深度学习研究尚不多见。

机载激光雷达数据的森林生物量估测通常限于单一区域。由于数据覆盖范围囿于局部区域, 易出现单一区域地面样本有限的情况, 从而难以建立可靠的森林生物量估测模型; 因此, 多区域样地和激光雷达数据联合建模成为提高估测模型可靠性和鲁棒性的重要手段 (Sun等, 2024)。虽然机载激光雷达数据在森林生物量估测中具有优势, 但其覆盖范围通常为林分尺度, 难以实现区域甚至全球尺度监测。由于数据采集和处理成本较高, 难以实现时间连续的大范围观测, 无法满足对森林动态变化的长期监测需求。

2.3 星载激光雷达数据的景观(区域)尺度森林生物量估测

星载激光雷达能够提供全球范围的观测数据, 是目前区域或全球尺度森林生物量研究的重要数据源 (庞勇等, 2019; Duncanson等, 2020)。美国于2003年发射了第一颗激光测高卫星 ICESat (Ice, Cloud and Elevation Satellite) GLAS (Geosciences Laser Altimeter System), 提供 2003 年—2009 年的全球数据 (Duncanson等, 2010; Lefsky, 2010)。2018 年发射的 ICESat-2 ATLAS (Advanced Topographic Laser Altimeter System)、GEDI (The Global Ecosystem Dynamics Investigation) 以及中国发射的首颗森林碳汇主动联合观测的遥感卫星“句芒号”在技术上有了大幅改进, 为大范围森林生物量估测提供了新的研究手段 (Narine等, 2020; Dorado-Roda等, 2021; Liu等, 2021a; Du等, 2024)。表4总结了星载激光雷达数据的森林生物量估测方法。

2.3.1 基于GLAS数据的森林生物量估测

GLAS采用全波形采样系统对陆地表面进行光斑采样, 系统发射的脉冲在地面形成约 70 m 的圆形光斑, 条带内相邻光斑间距 170 m, 条带之间从高纬度到赤道相距 2.5—15 km 不等, 是首个实现全球覆盖的卫星激光雷达数据 (Wang等, 2011),

对区域、国家、全球尺度的树高和生物量估测发挥了重要作用（Duncanson 等，2010；Lefsky，2010）。利用 GLAS 数据估计森林生物量的主要方法是通过提取原始波形指标将其用作估测生物量的预测变量（Zhang 等，2014），这些变量可以分为：（1）冠层高度变量，如最大、平均、中值和二次平均冠层高度（Lefsky 等，2005），中值能量的高度（Drake 等，2003）；（2）波形形态特征，如波形范围、前沿范围和后沿范围（Keller，2007）；（3）能量分位数（Xi 等，2016）；（4）冠层透射率变量：根据冠层透射率剖面计算出的分位数（Ahmed 等，2013）；（5）GLA14 产品中高斯峰的幅

度、高度、宽度和面积（Sun 等，2008）等。综合已有文献发现，GLAS 用于森林生物量估测的 RMSE 约为 52.20—58.30 t/ha，不确定性较大（Lefsky 等，2005；Zhang 等，2014；Nelson 等，2017；Zhang 等，2021b）。高斯分解是另一种用于从 GLAS 波形提取信息的方法，来自平坦、均匀森林区域将产生双峰回波，可以从两条高斯曲线来拟合（第一个代表树冠，第二个代表底层地形）。足迹内更多的离散元素（即树木、地形波动、树冠间隙）将增加构成波形的高斯曲线的数量（Lefsky 等，2005；Chi 等，2015）。

表 4 星载激光雷达数据的景观(区域)尺度森林生物量估测
Table 4 Forest biomass estimation at landscape (regional) scale based on spaceborne LiDAR data

数据特点	变量和模型	精度	关键文献
ICESat-1 GLAS: 数据全球覆盖, 光斑较大, 受地形影响严重	基于 GLAS 高度参数, 利用线性回归构建估测模型	巴西热带森林 RMSE=58.30t/ha; 国家尺度森林生物量 RMSE=9.38—43.81 t/ha	Lefsky 等, 2005; Chi 等, 2015
	基于 GLAS 波形高度参数, 利用支持向量机构建估测模型	中国东北人工林生物量 RMSE=58.29 t/ha	Zhang 等, 2014
	基于 GLAS 波形高度参数、冠层反射率剖面, 利用随机森林构建模型	中国长白山森林生物量 RMSE=52.20 t/ha	Zhang 等, 2021b
	基于 GLAS 波形高度参数, 利用对数模型	美国及墨西哥森林生物量 RMSE=39.58—65.10 t/ha	Nelson 等, 2017
ICESat-2 ATLAS: 空间分辨率高, 高度精度较好; 但难以获取复杂地形高植被覆盖的地面光子	利用 ATL08 高度统计变量, 利用线性模型	美国德克萨斯州人工林及西班牙人工林生物量 RMSE=24.91—35.85 t/ha; RMSE=7.76—17.71 t/ha	Narin 等, 2020; Guerra-Hernández 等, 2022
GEDI: 波束能力更强, 能够穿透密集植被; 陡峭地形下容易波形展宽效应, 足印定位误差	基于 GEDI L2A 相对高度, 利用幂函数	西班牙人工林 RMSE=14.13—32.16 t/ha; rRMSE=38.17—84.74%	Dorado-Roda 等, 2021
	基于模拟 GEDI 相对高度指标, 利用普通最小二乘法构建模型	全球尺度森林 RMSE=8.17—121.15 t/ha	Duncanson 等, 2020
ATLAS 和 GEDI 联合: 增强地理互补, 融合数据优势; 冠层高度的一致性模糊	基于 GEDI L2B 的冠层覆盖和 ATL08 冠层高度, 利用地理加权回归构建模型	中国东北地区 RMSE=38.64 t/ha	Chen 等, 2022
	基于模拟 GEDI 和 ATLAS 高度变量, 利用普通最小二乘法构建模型	美国加利福尼亚州 GEDI: rRMSE=26.77—34.87%; ATLAS: rRMSE=27.02—29.22%	Duncanson 等, 2020
	基于 GEDI 和 ATLAS 高度变量, 利用对数模型	中国浙江省 ATLAS: RMSE=31.25 t/ha GEDI: RMSE=39.26 t/ha	孟鸽 等, 2024

虽然 GLAS 在估测森林生物量领域已积累了大量成果，但同时面临着以下问题：1) GLAS 数据光斑较大（直径大约 70 m），波形易受地形影响，在地形起伏较大的区域，森林参数估测产生严重偏差（Wang 等，2011）；2) 不同 GLAS 指标对森

林生物量的估测作用仍未明确，阻碍了 GLAS 指标在不同森林或地区的使用。此外，当大量 GLAS 指标用于生物量估测建模而样本数量有限时，易导致模型过拟合现象，使得生物量估测精度较低。为克服上述 GLAS 数据局限性，ICESat-2 ATLAS 通

过采用光子计数技术来提升测量精度和空间分辨率,同时通过更高脉冲频率和更密集的采样提高数据覆盖范围。

2.3.2 基于ATLAS数据的森林生物量估测

ATLAS采用光子计数信号探测技术,具有高重复率和高灵敏度,可获得小足迹(约14 m)和高密度光子点云数据(沿轨道距离0.7 m)(Neuenschwander和Pitts, 2019; Neuenschwander等, 2020)。ATLAS系统设计为三对激光波束,每对包含一个强波束和一个弱波束,能量比约为4:1,波束在地面形成3组共6列相互平行的地面轨迹。ATL08是ATLAS生成的三级数据产品,专用于植被和地形分析,提供了沿轨道100 m分段的地表高程、冠层高度、冠层覆盖度等信息(Neuenschwander和Pitts, 2019)。然而,ATL08产品精度受地形地貌、冠层覆盖度、森林类型和数据获取方式(如强弱光束、夜间和白天数据)等因素影响(董佳臣等, 2021; Li等, 2024b)。在平原地区,ATLAS难以从稀疏的林分光子中准确识别冠层光子,导致对冠层高度的不准确估测(Wang等, 2024b);在山区,ATLAS在陡峭的地形和茂密的植被区域难以探测林下地形,导致ATL08的地面高程和冠层高度误差的增加(Zhu等, 2022),因此高精度数字高程模型(DEM)是提高局部地区冠层高度估测准确性的有效手段(Pang等, 2022)。但对于区域尺度或全球范围,在缺乏高精度DEM数据下如何提高ATLAS数据质量仍未解决,部分研究通过消除地面光子异常值以及对被错误分类为冠层或噪声的光子进行重分类,以提取优化的冠层高度(Gao等, 2022b; Zhao等, 2023a; Chen等, 2024b; Velikova等, 2024)。

近年来,关于ATLAS数据在估算森林生物量方面的评估已逐渐展开(Varvia等, 2024)。由于缺乏与ATLAS条带在空间和时间上一致的地面参考数据,通常使用同时期的机载激光雷达衍生的生物量作为参考(Narine等, 2020; Guerra-Hernández等, 2022)。从ATLAS衍生的平均高度、高度百分位以及冠层覆盖度(高度大于2 m的光子比例)作为预测因子,构建生物量估测模型(Narine等, 2020; Guerra-Hernández等, 2022)。这种方法构建的生物量模型受森林类型结构的影响较大,林

分复杂且年龄不同的森林,其模型预测误差较大($rRMSE=44.29\%$ 和 55.21%)(Guerra-Hernández等, 2022)。

由于光子计数系统对背景光和噪声较为敏感,ATLAS数据质量极易受复杂环境的影响。此外,该技术穿透能力较弱,高密度森林区域ATLAS光子大多集中于冠层顶部,难以有效捕捉地表信息,衍生的冠层高度变量出现较大偏差,进而影响到生物量估算(Guerra-Hernández等, 2022)。因此,进一步的研究将侧重于从ATLAS数据中提取更多的地面和植被光子,并利用额外的ATLAS属性数据(信噪比,高度测量不确定性及多反射面警告标志等)以最大限度地减少噪声和光子的误分类,并增强算法的鲁棒性(Chang等, 2024)。

2.3.3 基于GEDI数据的森林生物量估测

GEDI为全波形激光雷达系统,该系统共有3台激光器,共产生4束GEDI光束,这些光束通过光学抖动产生8条地面轨道,其激光点密度和光斑大小较GLAS均有极大改善(Potapov等, 2021; Duncanson等, 2022)。GEDI脉冲能量较ATLAS更高,发射的激光脉冲具有穿透树冠到达地面的能力,可获取森林垂直结构以及林下地形回波信息。通过对回波信息进行处理找到冠层回波位置与地面回波位置,二者对应的高差即为森林冠层高度(Duncanson等, 2022)。在提取森林垂直结构信息(包括冠层高度、冠层复杂度、异质性等)方面,GEDI已被证实比ATLAS产品更具优势,其中森林冠层高度在平原和丘陵地区表现出更好的精度(Li等, 2024b; Zhu等, 2022)。然而,GEDI存在由坡度引起的波形展宽效应,即在陡峭的地形上,冠层和地面回波往往会被拉伸和混合,降低了山区森林冠层高度精度(Liu等, 2021a; Wang等, 2024b)。尽管GEDI第二版相对于第一版数据在定位精度以及算法设置的选择上有所改进,但是GEDI的定位不确定性占冠层高度估计变化的50%(Ni等, 2021)。

GEDI L2A和L2B产品的冠层高度和垂直冠层结构指标常用于光斑尺度生物量估测,其 $rRMSE$ 大致位于34%—58%(Qi等, 2019)。与ATLAS数据相似,GEDI数据对不同森林类型生物量估测的效果差异较大(最小和最大 $rRMSE$ 分别为37.85%和84.74%)。为提高GEDI的森林生物量估测精度,

Ni等(2021)提出坡度自适应相对冠层高度指标,模型的 R^2 从0.48提高到0.68, RMSE从19.7 Mg/ha降低到15.4 Mg/ha。另外,为减小GEDI定位误差,基于同区域内参考DEM或者机载激光雷达数据,以一定搜索半径围绕每个足印质心遍历以确定最佳足迹位置(Liu等, 2021a; Wang等, 2024b)。GEDI常用的生物量估测方式为利用机载激光雷达模拟波形建立生物量方程,进而对森林GEDI光斑尺度生物量进行预测,其RMSE在8.17—121.15 Mg/ha范围(Duncanson等, 2022)。在缺乏机载激光雷达数据的情况下,GEDI数据的地理定位纠正颇具挑战性。高分辨率星载立体影像的获取可较好描述森林冠层顶部,为优化GEDI数据提供可能(Ni等, 2021)。GEDI存在的最大问题仍为激光回波受地形效应干扰较大,需进一步研究如何提高波形分解算法的精度,以更准确地区分冠层和地表反射信号。

2.3.4 基于句芒号和高分七号数据的森林生物量估测

句芒号和高分七号星载激光测高系统常用于植被结构探测和生物量估测任务。句芒号搭载了5波束的激光雷达和5角度多光谱光学相机,沿轨和横轨足印间距分别为200 m和4 km(曹海翊等, 2023)。句芒号单脉冲激光能量优于GEDI,提高了回波信噪比,较好地适应阳照区和阴影区。高分七号星载激光测高系统共搭载了4台激光器,2台足印相机以及1台光轴监视相机;激光沿轨向每个波束前后光斑间距约2.4 km,垂轨向两波束间距约12.25 km。目前利用高分七号和句芒号估测森林冠层高度和地形高度(李国元等, 2021;唐新明等, 2021),以及生物量估测方面的研究较少(Du等, 2024)。句芒号和高分七号均可获取激光雷达和多光谱数据,便于点面结合、主被动联合以实现大范围连续生物量估测制图。然而,上述两种卫星均面临激光点密度较低、覆盖范围有限、数据开放性低的问题。

2.3.5 联合 GEDI 和 ATLAS 数据的森林生物量估测

单独使用ATLAS或GEDI数据进行森林生物量估测仍存在局限,如ATLAS激光穿透能量较低,而GEDI缺乏对其地理定位不确定性的衡量。融合

这两种星载激光雷达数据的优势,可增加样本点密度以实现地理互补(Chen等, 2022; Duncanson等, 2020)。GEDI和ATLAS的联合方式分为两种:(1)利用GEDI L2B产品森林冠层覆盖变量和ATL08高度变量相结合,采用地理加权回归算法对条带生物量进行估测,该方法在中国东北森林区域试验结果良好, RMSE为38.64 Mg/ha;(2)直接联合两种数据分别预测生物量,作为后续估测区域生物量独立的样本(Duncanson等, 2020; 孟鸽等, 2024)。这是考虑到GEDI和ICESAT-2的足迹尺度生物量精度具有相似性(RMSE=26.77—34.87%)。

由于GEDI和ATLAS采用不同的数据获取技术,导致在森林高度估算上的不一致性,而且随着森林覆盖率的增加,这些差异呈现明显的变化趋势(Dorado-Roda等, 2021; Li等, 2024b)。通过结合逐步回归和随机森林算法建立一致性模型,减少GEDI和ATLAS之间的森林高度差异(Zhu等, 2022),可减小冠层高度不一致带来的森林生物量估测的不确定性。因此,两种星载激光雷达数据在区域尺度森林生物量估测中的适用性、以及数据融合对估算效果的影响,仍待进一步研究。

2.4 多尺度(机载—星载)激光雷达数据协同的区域森林生物量估测

基于面积的估测方法(Area-based approach)进行大范围的森林生物量估测建模通常需要大量样地调查数据,而调查数据数量不足及缺乏空间代表性常常导致建模困难。机载激光雷达凭借其高空间分辨率和捕捉精细森林结构的能力,常被用作连接有限的地面样地调查数据与中低空间分辨率遥感数据的桥梁(Jiang等, 2020b, 2023; Sun等, 2024)。估测空间离散的星载激光足迹尺度生物量时,由于难以匹配足迹与样地位置,缺乏真实样本数据,通常需要利用机载激光雷达估测的生物量图进行重采样并作为建模和验证样本,进而解决地面样本调查数据有限和缺乏空间代表性的问题(Coops等, 2021; Puliti等, 2018)。此类样本的灵活性还体现在其面积(如100—10000 m²)和形状(方形、矩形、圆形)的可调整性,可避免与影像像素、星载激光雷达足迹匹配不准的问题(Campbell等, 2021; Jiang等, 2020b)。

GLAS光斑约为70 m,在地形起伏的山区,难

以直接利用 GLAS 和野外调查数据构建生物量估测模型。而将机载激光雷达估测的生物量聚合成 70 m 尺度, 作为训练样本数据开发基于 GLAS 数据的估测模型是可行的方法。研究表明使用机载激光雷达的森林生物量模型可解释 83% 的真实样地数据, 而基于 GLAS 的估测模型可解释机载激光雷达生物量的 73% (黄克标等, 2013)。随着足迹更小的 ICESat-2 和 GEDI 数据出现, 机载激光雷达生物量图可重采样成传统样地的大小 (如 25.8 m×25.8 m 或 20 m×20 m), 可以近似地与 ICESat-2 (14 m×20 m) 和 GEDI (25 m 直径) 相匹配。当进行区域、国家和全球尺度范围研究时, 星载激光雷达 (如 GEDI 和 ICESat-2) 亦可有效补充无机载激光雷达覆盖区的样本 (Campbell 等, 2021; Dorado-Roda 等, 2021); 与全覆盖遥感数据 (如 Landsat) 联合使用时, 机载激光雷达生物量估计值可聚合成 30 m 像素 (Narine 等, 2020)。试验发现基于“典型区机载激光雷达一条带区星载激光雷达一大区域光学成像”的逻辑, 其生物量估测结果相较于传统“典型区一大区域光学成像”的方法, 误差下降了 10% 左右 (Campbell 等, 2021; Chen 等, 2022)。

除了直接利用基于机载激光雷达的生物量图作为样本外, 另一种方法是使用机载激光雷达数据模拟星载激光雷达数据的变量, 从而校准生物量模型, 减少地理定位误差导致的预测误差 (Duncanson 等, 2020)。通过机载激光雷达数据集对 GEDI 波形进行仿真, 并添加高斯白噪声, 提供与发射前分析预测相同的信噪比 (Hancock 等, 2019)。ICESat-2 模拟过程为将机载激光雷达数据的垂直分布作为光子从给定高度返回概率的代表, 对随机样本“光子”进行加权, 利用算法进行去噪和计算相对高度指数; 这些模拟的参数被用于训练在轨 GEDI、ICESat-2 数据的生物量校准模型。

机载激光雷达为星载激光雷达在全球尺度的生物量估测提供数据支持和校正。通过这种多尺度数据的联动, 可提高森林生物量估测精度, 并扩展其空间覆盖范围和时空连续性, 为实现全球范围内的森林生物量监测和评估提供技术手段。基于多尺度激光雷达联合进行森林生物量估测, 在以下方面需加强研究: (1) 多尺度的激光雷达数据采集原理和格式不同, 如何更好地融合基于各类平台所提取的激光雷达变量, 建立跨平台、

跨尺度的稳健生物量估测模型; (2) 真实样本和机载激光雷达生物量样本集是否会影响模型精度验证的结果, 如何分析机载激光雷达估测的生物量误差对后续星载激光雷达数据生物量建模的作用; (3) 星载激光雷达的足迹沿轨分布密度较高, 相邻或接近位置的值具有相似性或依赖性, 这可能导致生物量采样在空间上出现偏倚; 如何针对足迹级生物量估测进行样本空间采样, 并进行分析和对比, 确保样本空间特征的多样性和代表性。

3 联合激光雷达和其他遥感数据的森林生物量估测

在森林生物量估测研究中, 面对复杂的森林结构和生态环境, 单一遥感数据难以全面反映森林的垂直与水平结构特征。联合激光雷达与其他遥感数据可充分发挥各自优势, 如激光雷达获取垂直结构信息, 高光谱、多光谱或微波雷达数据在获取植被类型、植被盖度等方面。表 5 简要总结了机载激光雷达与高光谱或多光谱数据的结合, 以及星载激光雷达与光学、微波雷达数据及其他辅助数据的结合以提高森林生物量估测精度。

3.1 机载激光雷达与光谱数据协同的林分尺度森林生物量估测

3.1.1 机载激光雷达与高光谱数据的协同

以往研究中因数据源、算法和研究区特点等的不同, 对机载激光雷达和光学遥感数据的联合使用得出了不同的结论 (Laurin 等, 2014; 曹林等, 2016; Feng 等, 2017; Luo 等, 2017; Almeida 等, 2019; Gao 等, 2022a)。与光学多光谱影像相比, 高光谱影像因其丰富的窄波段特性, 涵盖从可见光到近红外及短波红外的多个光谱区间, 在描述森林的生理 (如叶绿素含量、水分状态和氮素浓度等) 和生态特征方面具有优势 (Almeida 等, 2019; Gao 等, 2022a)。因此, 高光谱影像和机载激光雷达数据的结合往往改善了森林生物量估测 (Luo 等, 2017; Almeida 等, 2019)。常用变量包括区分树种和生理状态的光谱反射率特征和植被指数, 以及描述林分结构异质性的树冠纹理特征。研究发现使用融合的机载激光雷达和高光谱影像数据, 所有森林类型的生物量估测精度提高了 8%—9%, 而天然林提高了 25% (Anderson 等,

2008)。在中国西北地区也证实，与单独的机载激光雷达指标相比，融合机载激光雷达和高光谱影像数据对生物量估测的RMSE降低了7.9%（Luo等，2017）。高光谱数据的波段数量庞大，在实际应用中需要进行降维或波段筛选，以减少计算复杂性并避免多重共线性问题。常用的降维方法包括主成分分析和连续投影算法，也可以结合随机森林等机器学习方法对波段重要性进行排序和筛选（Gao等，2022a）。

表 5 联合激光雷达和其他遥感数据的森林生物量估测
Table 5 Forest biomass estimation through combination of LiDAR and other remotely sensed data

数据获取方法	生物量估测方法	优缺点	精度	关键文献
机载激光雷达与高光谱数据的协同	从不同数据源中分别提取变量，经过变量筛选后，利用机器学习构建生物量估测模型	高光谱数据提供精细的树种识别结果，但数据处理复杂，对天气和光照条件敏感，成本高	$R^2=0.7-0.94$; RMSE=15.25—61.7 t/ha; rRMSE=15.16—33.1%	Laurin 等, 2014; Almeida 等, 2019; Heiskanen 等, 2019; Luo 等, 2017
机载激光雷达与光学多光谱数据的协同		多光谱数据获取成本较低，但光谱信息有限	$R^2=0.65-0.91$, RMSE=16.95—60.44 t/ha; rRMSE=20.00—40.1%	Feng 等, 2017; Heiskanen 等, 2019; 曹林 等, 2016
星载激光雷达与光学/微波雷达/辅助数据的协同	使用足迹级生物量作为参考样本，提取光谱变量，利用随机森林方法构建生物量估测模型	可降低无采样区域的生物量估测误差，但足迹级生物量的误差不确定性大	美国犹他州国家保护区： RMSE=12.71 Mg/ha; 中国东北塞罕坝： RMSE=56.36 Mg/ha	Campbell 等, 2021; Jiang 等, 2022
	利用调查样地，联合星载激光雷达衍生的空间连续冠层高度变量和环境因子，利用随机森林方法构建生物量估测模型	可直接通过真实样地建模；冠层高度产品具有饱和效应，影响建模效果	RMSE=70.71 Mg/ha	Yang 等, 2023b

3.1.2 机载激光雷达与多光谱数据协同

高分辨率多光谱数据，如国产高分系列、资源系列，国外的 QuickBird 等，包含可见光和近红外波段，虽然波段数较少，但其高空间分辨率能够提供丰富的空间特征信息。而中等分辨率多光谱数据，如 Sentinel-2 和 Landsat，尽管空间分辨率较低，但因有短波红外波段，能够提供有关植物水分含量、土壤背景和林木生理状态的额外信息（Zheng 等，2023；曹林 等，2016），使其成为林分尺度森林生物量估测的重要数据源。在整合多源数据时，如何选择适合的变量来估算生物量是个挑战（Li 等，2019；Gao 等，2022a）。仅使用激光雷达数据时，常见的变量选择方法是逐步回归。然而，使用多源数据时，不同类型的变量（如高度变量、地形或土壤相关的变量）无法满足生物量与这些变量之间的线性关系假设（Lu 等，2016）。因此，需要选择能够处理非线性关系的方法。递归特征消除法是机器学习建模中常用的特征选择方法之一，其主要目标是通过逐步消除不重要的特征来减少模型复杂性、提高模型性能、降低过拟合

风险，并增强模型的可解释性（Feng 等，2017）。与之相比，Gao 等（2022a）采用了三级特征筛选策略，有效避免了特征冗余问题，并减少了在测量样本较少情况下的无关特征。该方法先对激光雷达和高光谱特征进行单独筛选，再对两种数据源融合后的特征进行筛选。这些变量选择方法的目的是在不损失太多生物量估算精度的前提下，显著减少用作输入的变量数量，构建简洁的模型。虽然多源数据的结合有助于提高生物量估算精度，如何优化变量选择应对不同森林类型和生长阶段的生物量估算，需进一步探索更有效的建模方法和数据融合策略，以提高估算的可靠性和精度。

3.2 星载激光雷达与光学/微波雷达/辅助数据协同的森林生物量估测

星载激光雷达与光学/微波雷达遥感数据联合克服了星载激光雷达不连续地面采样的局限性，实现区域或全球尺度空间连续的森林高度和生物量的估测制图（Chi 等，2015；Liu 等，2022；Potapov 等，2021）。常被选用的光学遥感数据如 Landsat、Sentinel-2 通过其丰富的光谱信息有效捕

捉不同森林类型的冠层反射特征 (Narine 等, 2019)。而微波雷达的优势在于全天候数据获取, 且不受云层遮挡的影响。除了遥感数据, 由于地理空间跨度大、立地条件和气候各异等问题, 环境因子 (如气候、土壤类型、坡度和海拔高度等) 也在森林生物量估测中发挥着重要作用。

当 GLAS 和 MODIS 数据联合时, 因 MODIS 空间分辨率低, 大量的混合像元和较大的地面光斑, 导致森林参数估测不确定性较大 (Chi 等, 2015; Zhang 等, 2014)。近年来, 联合质量改进的星载激光雷达 (GEDI、ATLAS) 和光学/微波雷达/辅助数据已成为大范围森林生物量估测制图的趋势 (Liu 等, 2022; Potapov 等, 2021)。利用星载激光雷达估测大范围生物量的方法可以分为两类: 第 1 类是利用星载激光雷达的足迹级生物量数据 (基于样地和机载激光雷达数据构建模型预测的结果, 或 GEDI L4A 产品) 作为参考样本用于生物量估测建模。基于传统样地和机载激光雷达建模估算典型区的生物量, 再利用典型区内 ICESat-2 和 GEDI 提供的树高和冠层结构参数, 分别估测 ICESat-2 和 GEDI 光斑的森林生物量, 结合森林类型与全覆盖遥感数据将光斑尺度的森林生物量外推到逐像元尺度, 获取大范围区域森林生物量 (Chen 等, 2022)。另外, GEDI L4A 级森林生物量产品的推出为缺少样地调查数据或无机载激光雷达采集的区域提供了替代参考数据集。然而, 研究发现使用 GEDI L4A 作为参考样本获得的 RMSE 值比使用真实样本获得的 RMSE 值高 8—9 倍 (Pascual 等, 2023)。GEDI 和 ICESat-2 数据可使用网格或对象为单元联合光学、微波雷达等数据进行生物量估测建模 (Mareya 等, 2018; Silveira 等, 2019)。传统的基于网格的方法常用于各种尺度的建模和全面的森林参数制图, 但也有研究表明当使用面向对象的方法时, 生物量估计精度会有所提高 (Silveira 等, 2019)。

第 2 类是将基于星载激光雷达衍生的空间连续冠层高度产品作为变量参与建模。冠层高度产品可以缓和光学或微波雷达在估测森林生物量时的饱和现象。为了克服星载激光雷达本身空间离散问题, 与光学/微波雷达影像融合以生成空间连续的森林冠层高度, 从而估测森林生物量 (Jiang 等, 2022; Zhang 等, 2014)。以星载激光雷达足迹处的森林冠层高度为参考数据, 光学/微波雷达影像

作为预测变量, 构建回归高度模型 (Chen 等, 2022; Duncanson 等, 2022; Lefsky, 2010)。该策略未充分利用星载激光雷达数据, 在回归过程中, 足迹位置的森林冠层高度精度反而会下降 (Lang 等, 2022; Potapov 等, 2021)。因此, 另一种方法是利用特征距离插值, 直接依据 GEDI 和 ICESat-2 ATLAS 足印和地形、气候、植被指数等数据绘制大范围森林冠层高度分布 (Liu 等, 2022)。

虽然联合星载激光雷达与其它遥感数据是大范围森林生物量估测制图的重要手段, 但估测结果不确定性大。使用星载激光雷达的足迹级生物量作为建模样本的流程需要重视误差传递的问题, 不仅要考虑不同尺度 (样地—机载激光雷达—星载激光雷达—区域) 生物量的估测误差, 还要考虑作为因变量的来自前一步产生的误差累积。另外, 联合光学影像反演全覆盖的冠层高度产品仍具有挑战, 因为光谱特征和森林参数之间的物理关系复杂, 机理仍未明确。虽然大量的星载激光雷达足迹可提高模型估测精度, 但生成的森林冠层高度变量仍然受到饱和效应的影响 (Araza 等, 2022; Yang 等, 2023b), 进而影响区域生物量估测精度。

4 森林生物量估测建模方法

建模方法的选择是森林生物量估测过程中关键一环。传统的多元回归方法, 随着数据特征的复杂性增加, 其适用性逐渐受到限制。近年来, 机器学习和深度学习方法由于其强大的数据挖掘能力, 成为森林生物量估测中重要的研究方向。此外, 结合物理模型和机器学习算法的混合模型, 也将成为生物量估测研究中新的发展趋势。表 6 简要地总结了这些估测建模方法的特点。

4.1 基于多元回归的森林生物量估测建模方法

多元回归模型是森林生物量估测中最常用的建模方法之一 (Lu 等, 2016), 其核心思想是通过线性或非线性回归分析, 将激光雷达提取的结构变量与实地测量的生物量数据相关联。多元回归模型包括线性、逻辑、指数和 Richards 等具有直接可解释性的方程 (Xie 等, 2023)。在林分密度或冠层覆盖度相对较低的人工林区域, 线性回归是最常用的建模方法 (Nie 等, 2017; Jiang 等, 2020a), 但对于诸如热带地区的原始森林和密度大的次生

林，使用对数或平方根的非线性变换用作响应或解释变量，有助于提高模型的估测精度（Longo等，2016；Phua等，2016；Feng等，2017）。多元回归模型的主要优势在于其简洁性和可解释性，使得研究者能够快速建立生物量估测模型，并明确变量与生物量之间的关系。针对单一森林类型，

基于激光雷达的高度变量如高度百分位等，线性回归模型通常能有效地预测生物量（Heiskanen等，2019；Jiang等，2020a；Lin等，2022）。然而，由于其对线性假设的依赖，多元回归模型在处理复杂的非线性和高度异质的森林结构时表现出局限性（Gao等，2018；Jiang等，2020a）。

表6 森林生物量估测建模方法

Table 6 Modeling methods for forest biomass estimation

方法	方法描述	优缺点	关键文献
多元回归模型	筛选一个或多个自变量,构建与森林生物量之间的线性或非线性关系,常用方法包括线性回归、偏最小二乘回归等	建模方法简单、易解释,易于实施和解读,计算效率高。但对变量线性假设敏感,容易受到多重共线性影响,对复杂非线性关系的适应性差	Nie等,2017;Longo等,2016;Lin等,2022
机器学习	利用非参数化算法,如随机森林、支持向量机、梯度提升决策树等构建生物量估测模型	能捕捉复杂的非线性关系,对高维数据和多源数据处理能力强。但需要大量训练数据,解释性较差,模型超参数调优复杂,计算资源需求较高	Rex等,2020;Marchesan等,2023;Xie等,2023
深度学习	通过深层神经网络(如卷积神经网络、长短期记忆网络)学习生物量与各种变量的非线性映射关系	优秀的特征提取能力,在处理高维、复杂的多源数据时表现优异,自动化学习过程。但需要大量样地数据,训练时间长,计算需求高,模型不透明,难以解释	Zhang等,2019;Oehmcke等,2024
混合模型	将物理模型与机器学习算法结合,以弥补单一模型的不足	结合物理机制与数据驱动方法,提高预测精度,能更好地应对数据稀缺的情况。但模型结构复杂,计算复杂度较高	沈焕锋和张良培,2023

4.2 基于机器学习的森林生物量估测建模方法

机器学习方法，包括K-最近邻、人工神经网络、随机森林、支持向量机和最大熵等，能较好地解决非线性和高维数据（多源数据时）问题，但其模型性能有所不同（Lu等，2016；Gao等，2018）。复杂的树种组成和环境条件（如地形、土壤、湿度），导致生物量与建模变量之间的复杂关系，难以简单地用线性关系来构建。机器学习具有较强的处理参数间复杂非线性关系的能力（Xie等，2023），尤其是当激光雷达、光学、微波雷达和各种辅助数据用于森林生物量建模时，机器学习具有处理多源数据的优势，无需考虑输入数据的要求以及生物量与输入变量之间的关系。

比较不同机器学习算法在森林生物量估测中的性能发现，支持向量机和随机森林比其他机器学习算法表现更好，可能是这两种方法可以处理相对较少数量的样本，具有良好的泛化能力（Marchesan等，2023；Xie等，2023）。支持向量机方法通过搜索最佳超平面来构造最大间隔分离器，并用有限的训练样本适当地推广给定模型。

随机森林算法是一种使用多决策树的集成学习方法，可以减少过拟合问题，对数据噪声和异常值不太敏感。近年来，将弱学习器转化为强学习器的Boosting算法，如极端梯度提升机和轻梯度提升机，在利用多源数据进行森林生物量估测方面有良好的表现（Fang等，2022）。然而，此类方法容易受到超参数设置的影响，当可用样本数量有限时表现不稳定。

4.3 基于深度学习的森林生物量估测建模方法

深度学习对多源数据的强大数据挖掘能力也被用于生物量估测研究（Zhang等，2019；Ghosh和Behera，2021；Tian等，2023）。深度学习可自动提取不同于人工特征的抽象特征，通过使用多层网络来捕获和解释数据中的不同复杂程度，以提高生物量估测准确性（Ghosh和Behera，2021）。比如，具有结合光学和激光雷达变量输入的堆叠稀疏自动编码器网络模型在森林生物量估测方面提供了比机器学习算法（如K最近邻、随机森林和支持向量机）更好的估测性能（Zhang等，2019）。卷积神经网络模型可使用一系列可训练的

移动窗口来解释空间数据,其性能优于其他经典机器学习算法(Du等,2021; Talebiesfandarani和Shamsoddini,2022)。然而,基于激光雷达数据使用深度学习算法来预测森林生物量的研究还很罕见,主要是由于该方法对样本数据要求很高。从机载激光雷达数据人为衍生的特征和二维数据(而不是三维图像),已被应用于深度学习模型(Zhang等,2019; Du等,2021),但也导致深度学习模型提供的自动特征提取和选择优势的丧失。当训练数据有限时,深度学习拟合数据的能力未必会超过其他机器学习方法(Talebiesfandarani和Shamsoddini,2022)。如果直接使用点云数据作为输入,需要考虑数据量、处理速度、模型复杂性和泛化性等问题(Tian等,2023; Oehmcke等,2024)。样本数据的不足可能是制约深度学习在森林生物量估算研究中的关键问题。多源数据的广泛应用和样本数据的共享将为深度学习进行森林生物量估测研究提供强有力的支撑。

4.4 基于混合模型的森林生物量估测建模方法

基于数据驱动模型可以充分挖掘数据特征来构建生物量估测模型,但该方法过于依赖地面观测数据,缺乏生态生理的理论支持,也缺乏模型的可迁移性。生物量估测的物理模型是从物理规律出发,构建从观测数据到生物量之间的表达式,也称为模型驱动的方法(杨倩倩等,2022; 龚健雅和李彦胜,2022)。这种模型使观测数据和目标参数之间具有明确的因果关系,模型建立过程透明,可解释。但物理建模的方式难以准确地描述复杂多变的现实情况,贴近实际的模型往往复杂且成本高昂,调参过程也因地理分区的不同而变化,给建模带来巨大的困难。一种可行的方式是,联合物理模型和机器学习缓解物理模型的“偏见”,同时避免机器学习模型的“傲慢”,为生物量估测提供新的研究方向(沈焕锋和张良培,2023)。根据两种模型的主体位置不同,混合建模方法可以分为以机器学习为主和以物理模型为主。

机器学习辅助物理模型的方法:从数据驱动的角度优化训练数据、理论模型和模型参数,提高物理模型的估测精度。生态过程模型是估测生物量的主要物理、机理模型。过程模型主要依赖于关键性的生态过程,其优势是包含了植物生理生态的规律,具有在持续变化环境下的长期预测

能力,并且能同时考虑人为或自然干扰对森林长期生产量的影响(朴世龙等,2022; 谢馨瑶等,2018)。常见的过程模型有iLand(Seidl等,2012)、InTEC(Chen等,2000)和3-PG(Landsberg等,2003)等。机器学习的融入可从以下方面对模型进行优化:(1)观测值和模型模拟值之间的误差可能来源于模型设置的缺陷,而机器学习能识别并降低这种系统误差(Pathak等,2018; Reichstein等,2019);若观测数据缺失,也可以通过机器学习的方式填补;(2)将机器学习算法直接嵌入过程物理模型,通过半经验方法输出模拟结果,使复杂的物理模型更适用于大范围估测;(3)物理模型的参数往往数量众多且难以表征,机器学习算法可以加速参数的优化和不确定性评估。然而,生态过程模型的主要输入数据为气象、土壤等要素,分辨率通常较低,以物理模型为主体的混合建模方法也许不适用于森林异质性强的生物量估测。

以机器学习模型为主导,将物理模型有关的先验知识引入机器学习,增强模型在不同地理分区的可迁移性,提高它的合理性及可解释性,提升模型的效率和精度(Shen等,2023)。协同物理模型的途径可分为3种:(1)样本级协同:将模型模拟生物量数据作为机器学习的扩充样本,使得数据驱动模型可以学习到物理特征,但是附加样本和原样本集之间异质性可能较大;(2)模型级协同:将物理约束作为机器学习损失函数的附加项。模型训练时,不仅要最小化数据误差,还要最小化物理信息误差,确保预测结果符合物理定律;(3)结果级协同:在网络训练后利用物理模型对其进行评估和检验,对生物量反演结果二次修正以排除异常值。

联合物理模型和机器学习的方法在森林生物量遥感定量估测方面研究甚少。森林生物量增长速率随着生长呈现先升高后降低再趋于稳定的状态,这和生长曲线的特征有着异曲同工之妙,为机器学习融合物理模型打下理论基础。理论生长曲线是在生物学原理假设的基础上,用来模拟生物体大小或生长的微分方程,通过引入相关因子,可模拟生物的生长。这些方程具有逻辑性强、应用广泛、参数可做生物学解释等特点,并从理论上对未来生长趋势进行预测。主要方程包括Richards、Korf、Logistic、Mitcherlich、Gompertz、Schumacher

等 (Salas-Eljatib 等, 2021; Zeide, 1993; Zhang 等, 2019)。然而, 这种研究仍处于起步阶段, 需要探讨如何将生态学上公认的机理知识参与到机器学习, 构建森林生物量估测的混合模型。

4.5 分层构建生物量估测模型提升估测精度

森林生物量估测研究中往往基于单个研究区的数据, 缺乏空间代表性的样本数据, 构建的估测模型也缺乏鲁棒性和可扩展性 (Jiang 等, 2020a; Lin 等, 2022)。如何联合多个研究区的样地和激光雷达数据已成为提高森林生物量估测模型可靠性和鲁棒性的重要手段 (Sun 等, 2024; Jiang 等, 2023)。然而, 将所有样本直接用于总体估测建模往往未能充分考虑森林结构与环境条件的区域差异, 影响建模效果和估测精度。一种简单而有效的方法是分层建模 (Zhao 等, 2016b; Heiskanen 等, 2019; Lin 等, 2022)。不同因子如森林类型、环境条件 (例如地形特征、土壤类型和气候条件) 和研究区域的差异等常用作分层因子 (van Ewijk 等, 2020; Jiang 等, 2020b)。考虑森林生物量主要由树种、胸径和树高决定, 森林类型分层是生物量建模中最常用的方法 (Cao 等, 2014; Heiskanen 等, 2019)。如基于森林类型分层的生物量估测模型将亚热带森林的估测, $rRMSE$ 从未分层的 38.01% 降低到马尾松的 20.05%、杉木的 18.73% 和桉树的 24.82% (Jiang 等, 2020a)。除特定树种组外, 其他森林组包括常绿林和落叶林 (Anderson 和 Bolstad, 2013)、经济林和次生林 (Feng 等, 2017), 以及毛竹的大年和小年等都是潜在的分层因子 (Chen 等, 2018)。

除了森林类型, 另一种分层方法是基于环境变量, 如地形和土壤条件。不同的立地条件会影响树木的生长, 影响树高和生物量之间的关系。基于山谷、斜坡和山脊等地形位置的分层可以降低垂直异质性并突出水平变化, 特别是在使用光学传感器数据时 (Molina 等, 2015; Zhao 等, 2016b)。然而, 对于高密度点云的激光雷达数据, 受地形影响较小, 地形因素分层对模型性能的提升相对有限 (Lin 等, 2022)。由于激光雷达数据范围有限, 且环境条件相似, 基于环境因素的分层对建模性能的影响远小于森林类型 (Kanmegne Tamga 等, 2022)。由于不同地区的气候、地形、土壤条件甚至管理实践的差异, 模型预测在地理

区域之间存在显著差异 (van Ewijk 等, 2020)。在现实中, 样地数量是决定分层策略的关键, 太多的分层需要大量的样地, 考虑到工作量和成本, 收集大量实测样地数据往往是一项具有挑战性的任务。

为克服分层建模时样本数量不足的问题, 混合效应和分层贝叶斯等模型提供了新思路 (Chen 等, 2012; Lin 等, 2022)。混合效应模型是一种能够自然地考虑单个观测之间相关性的统计方法, 其思想是对观测结果分为不同的组, 并允许模型参数随着组间随机变量的实现而变化 (Chen 等, 2015b)。混合效应模型是在用一个模型拟合所有数据点和分别为每个组拟合模型之间提供了一种平衡, 适用于稀疏样本分布 (Feng 等, 2021)。分层贝叶斯模型允许将先验知识纳入模型中, 这有助于缓解小样本的问题。同时, 分层贝叶斯模型提供参数的概率分布, 有助于量化参数估计的不确定性, 这对于小样本情况至关重要 (Wang 和 Blei, 2018)。此外, 研究表明双因素分层贝叶斯模型 (如森林类型和坡向) 比单因素分层贝叶斯模型 (森林类型) 提供更好的森林生物量估测结果 (Lin 等, 2022; Sun 等, 2024)。

尽管混合效应模型和分层贝叶斯模型可以在一定程度上缓解小样本导致的分层建模难题, 但是过多的分层反而可能影响模型的可靠性。如何确定合适的分层因子和合理的分层数目成为新的挑战 (Jiang 等, 2020a)。未来的研究可以考虑根据影响因子的不同权重创建复合分层因子, 综合反映森林生物量的结构和环境特征, 优化分层策略。在提高估测精度的同时, 控制模型复杂性, 更高效地利用有限的样地数据资源。

5 模型的不确定性分析及森林生物量估测建模过程的优化

不确定性分析是森林生物量估测建模过程中重要的一环。不确定性因素主要来自 3 个方面: 样地、激光雷达数据及变量的提取、模型构建。以往由于样地数量的限制及影响机制的不清楚, 不确定性分析没有得到应有的重视。通过不确定性分析, 正确理解不同因素对生物量估测建模的影响, 对优化建模过程, 提高模型估测精度具有重要意义。

5.1 影响生物量估测的不确定性因素

基于激光雷达数据的森林生物量估测模型精度受众多因素的影响,包括样地测量误差、异速生长方程的选择、遥感数据与样地的几何配准、激光雷达数据和变量的选择、生物量估测模型的选择等(Lu等,2016)。这些因素引起的误差会累积到最后的估测结果中,导致生物量的估测和制图存在很大的不确定性(Chen等,2015a)。随着生物量估测研究的深入,对估测过程中不确定性因素及误差传递的分析逐渐得到重视(Araza等,2022)。

生物量建模所需的样地数量取决于森林环境的复杂性、所选建模方法和精度要求等因素(Grafström和Ringvall,2013)。样本数量不足往往导致所构建的估测模型可靠性和鲁棒性差,最终引起估测结果的精度下降(Bouvier等,2019)。准确的野外测量和选择适当的异速生长方程是提供高质量生物量参考数据的两个关键因素。胸径易于精准测量,然而在林区树高的测量尤其困难。树高的测量误差在不同森林类型中变化较大,热带森林中因环境复杂测量误差可达3%—20%(Hunter等,2013),而温带森林则因林分相对简单而显著降低至7.8%左右(Phillips等,2000)。Liao等(2022)以伐倒木实际树高作为真值,基于测高杆量测的亚热带马尾松和桉树的树高误差达9.0%和9.9%。

异速生长方程是基于采样树的胸径、树高和木材密度等测量数据建立的。模型参数会因立地条件的不同而存在显著差异。根据异速生长方程和评价方法的不同,异速生长方程不确定度占总不确定度的30%—75%(Saarela等,2020;Vorster等,2020)。当外业工作中树高数据难以获取时,单独利用胸径计算的样地生物量具有较高的不确定性(Liao等,2022)。这是由于即使胸径相同,生长在不同地形和土壤条件下,树高的差异也很大。部分树种没有对应的异速生长方程,只能借用相近类别的异速生长方程,同样造成较高的不确定性(Yang等,2023a)。在森林生物量估测中,通常默认将实测样地当作无误差的真实样本值,不考虑测量、异速生长方程选择误差或者假设一定比例的误差对区域水平的估测结果的影响(Chen等,2015a)。

样地位置的误差对生物量估算的影响也不能忽视。以往的研究提供了关于样地大小和配准误差对激光雷达森林生物量估算准确性和不确定性的模拟分析,发现配准误差越大,生物量估算误差越高(Frazer等,2011;Hernández-Stefanoni等,2018)。当样地配准误差达到10 m时,小样地(面积为400 m²)的生物量估测不确定性增加至30%以上,较大样地(面积为1000 m²或更大)能够显著减少不确定性,误差通常低于10%—15%(Frazer等,2011)。

激光雷达数据本身的误差也是影响生物量估算的因素之一。基于地基激光雷达数据可获得更为精确的树木三维结构,这种方法无需依赖异速生长方程即可直接获取单木材积,进而乘以木材密度得到单木生物量。与异速生长方程相比,基于地基激光雷达的方法在精度上更接近破坏性测量值,rRMSE仅为26.01%;而基于异速生长方程的rRMSE高达38.8%—50.69%(Singhal等,2021)。在机载激光雷达技术的应用中,一些研究尝试结合单木检测方法分析生物量估测的不确定性及其误差传播过程(Xu等,2018)。尽管机载激光雷达数据无法直接获取胸径相关信息,但它可提供准确的树高测量。Liao等(2022)以伐倒木作为参考,发现高密度激光雷达点云数据提取的树高误差仅为3.2%(马尾松)和2.7%(桉树);因此,可建立树高相关的异速生长方程。然而,从单木尺度到样地尺度生物量估测中存在多个不确定性来源,包括单木识别过程中的遗漏和错分、单木参数估测误差、异速生长方程的参数不确定性以及模型残差不确定性。在单木尺度上,基于树高建立的异速生长方程残差对总不确定性的贡献最大(87%—99%)。而从单木汇总至样地时,机载激光雷达数据检测的样地内单木株数RMSE为31.61(55.52%),这一误差占激光雷达推算的生物量总不确定性的48.68%(Xu等,2018)。在林分或区域尺度,机载激光雷达模型的不确定性主要来自飞行高度、激光器参数及点云密度的差异,尤其是在复杂地形区,地面回波获取不完全会影响模型精度(Guo等,2021)。星载激光雷达模型的不确定性更加突出,主要受到低分辨率和大气条件变化的影响,信号噪声和激光束斑的扩展常导致生物量估算的精度下降(Zhu等,2022)。GEDI第二版产品的定位不确定性占冠层高度估算变化的50%,并对

冠层空间异质性的估算影响更为显著（Ni 等，2021）。

在所有误差来源中，模型误差，包括模型残差和参数误差，对生物量估算的不确定性贡献也不容忽视（Breidenbach 等，2014）。参数不确定性主要来源于模型训练过程中参数估计的偏差，尤其是在数据量有限或变量选择不当的情况下。例如在热带森林区域，参数误差导致的像元尺度生物量预测误差为 16.2%，且模型参数误差随着样本量的增加而减小（Xu 等，2018）。残差不确定性则来自模型无法完全捕捉到的变量与生物量之间的复杂关系，尤其在复杂森林结构和环境条件变化时更加明显（McRoberts 和 Westfall，2014）。残差

误差导致的像元尺度生物量预测误差为 47.9%，对像元尺度总误差（参数误差，残差和激光雷达变量误差）的不确定性贡献可达 80.5%（Chen 等，2015a）。

5.2 模型的不确定性分析方法

误差普遍存在于森林生物量估测过程的各个阶段，导致最终估测结果的不确定性。多种方法包括蒙特卡洛模拟、误差传播分析、贝叶斯分析、多项式回归分析、泰勒级数等可用于量化不确定性因素（Lu 等，2012；Chen 等，2015a；Varvia 等，2017；Xu 等，2018）。表 7 总结了常见的生物量估测不确定性分析方法。

表 7 常见的生物量估测不确定性分析方法
Table 7 Common uncertainty analysis methods for biomass estimation

方法	简要描述	优缺点	关键文献
泰勒一阶展开方法	通过线性近似传播输入误差到输出误差	计算效率高;适用于简单模型。对非线性模型效果差;忽略变量间交互作用	Chen 等,2015a; Xu 等,2018
蒙特卡洛模拟法	通过大量随机采样,模拟输入变量的不确定性及其对模型输出的影响。适用于复杂和非线性系统	适用于任何模型结构,能处理高维非线性问题。计算成本高,需要大量计算资源。结果依赖于采样次数和分布假设	Frazer 等,2011; Jiang 等,2023
敏感性分析	通过评估输入变量变化对模型输出的影响,识别关键变量和不确定性来源。常用方法包括局部敏感性分析和全局敏感性分析	能有效识别输入变量的重要性,适用于高维数据和复杂模型。局部敏感性分析无法考虑变量之间的交互作用。全局敏感性分析计算复杂度较高,尤其是对于非线性模型	Zhang 等,2023; Jiang 等,2023
贝叶斯分析	利用贝叶斯统计方法,通过引入先验分布和后验概率,对模型参数和输出不确定性进行全面量化	能充分利用先验信息,提高模型的解释力,适用于不确定性较大的复杂模型。先验分布的选择对结果有较大影响	Varvia 等,2017
误差传播分析	通过量化输入数据误差在模型中的传播过程,评估输出结果的不确定性。常用于线性和非线性模型的误差评估	能直观量化输入误差对输出结果的影响,适用于简单模型的快速误差评估。对非线性模型的误差传播过程难以准确描述。假设输入误差为独立同分布,可能低估实际误差	Chen 等,2015a; Xu 等,2018

基于激光雷达数据的生物量估测常用线性或非线性的参数模型。泰勒一阶展开方法由于计算效率高，适用于简单模型而被广泛使用。该方法通过对模型输出变量（生物量估测值）的误差传播进行线性近似，定量解析输入变量（激光雷达衍生的变量）误差如何影响输出变量的不确定性（Chen 等，2015b；Xu 等，2018）。然而，该方法无法直接拆解残差误差，因为它是由模型本身的拟合能力或数据误差引起的，需要基于拟合结果与实际数据之间的比较分析。同时，该方法假设输入变量相互独立，如果输入变量相关性较强，误差分解可能不准确。

蒙特卡洛模拟法通过对输入变量的分布进行随机抽样，量化输出变量的不确定性，是研究不确定性传播的经典方法（Gonzalez 等，2010；Frazer 等，2011；Berger 等，2014）。Frazer 等（2011）利用蒙特卡洛模拟法评估样地与激光雷达数据配准误差（随机方向，1—5 m 的距离误差）对生物量估测的不确定性影响。敏感性分析经常与蒙特卡洛模拟法联合使用来分析模型的不确定性。通过对模型输入变量加入随机误差（限定误差范围），模拟上万次从而评估模型对输入变量不确定性的响应，揭示模型输出的变化范围（Jiang 等，2023；Zhang 等，2023）。二者结合的方式可

考虑到多个不确定性来源和模型的非线性性质相关的复杂性 (McRoberts 和 Westfall, 2014)。

贝叶斯模型因其固有的概率框架, 能较好地度量模型的不确定性和估计的置信区间 (Varvia 等, 2017; Lin 等, 2022)。基于机载激光扫描数据和航空图像采用贝叶斯推理框架, 估算样地水平下特定树种生物量不确定性的量化研究, 发现该方法能很好地量化预测的不确定性, 并能在训练数据充足的情况下对特定树种的生物量产生最优区间估计 (Varvia 等, 2017)。

误差传播分析假设模型的输入存在不确定性或误差, 这些误差通过模型计算逐步传播并影响输出结果。对于线性模型, 误差传播较为直观, 通常可以通过一阶泰勒展开进行分析 (Xu 等, 2018)。对于非线性模型, 误差传播更加复杂, 因为输出不仅受单个输入变量的影响, 还涉及到变量之间的交互作用。此时通常使用一阶泰勒展开或蒙特卡洛模拟等方法来估算误差的传播 (Chen 等, 2015a)。不同于其它不确定性分析方法仅对单个生物量估测模型进行不确定性度量, 误差传播分析被用于计算单木 (测量误差, 异速生长方程误差) 一样地 (机载激光雷达与样地的生物量估测模型误差) 一像元尺度 (激光雷达衍生变量的误差) 的累积误差 (Chen 等, 2015a; Xu 等, 2018)。

大多数研究集中在单一尺度数据下的不确定性分析, 关于近地面—机载—星载激光雷达数据整合过程中的误差传递机制的研究仍然罕见。常见的做法是默认误差独立, 直接累加每个部分的误差 (Campbell 等, 2021)。然而, 每一种数据源的空间分辨率、数据采集方式及应用场景不同, 导致误差在跨尺度数据整合时具有复杂的传递特性, 需要更多研究来探索如何定量评估这些误差的传递。例如, 利用误差传播模型和多尺度联合建模方法, 分析不同尺度之间的数据如何相互影响并传递不确定性。在大范围森林生物量估测研究中, 尤其要重视模型估测的不确定性分析和误差传递特性。

5.3 通过不确定性分析优化森林生物量估测建模过程

不确定性分析的目的是揭示生物量建模过程中的误差来源, 通过量化不确定性因素, 为优化生物量估测建模过程提供依据 (Lu 等, 2016)。以

往的研究主要关注建模变量的提取和筛选, 以及模型构建方法。对如何优化设计整个建模过程缺乏分析和梳理。

影响生物量估测的不确定性因素有参考数据、输入数据和模型3大类。参考数据中, 异速生长方程是造成单木级生物量不确定性的最大误差源 (Xu 等, 2018; Vorster 等, 2020), 这表明未来的工作更值得投入到减少异速生长方程带来的不确定性上。以往的研究中因没有充分考虑异速生长方程引起的不确定性, 其生物量估测结果中可能得出了过于乐观的精度 (Xu 等, 2018)。优化采样设计以确保样地分布的空间代表性, 进而减少采样偏差是提升生物量估测精度的方法之一 (Chave 等, 2004; Lu 等, 2012; Araza 等, 2022)。利用不确定性分析识别模型预测中的不稳定性区域, 可针对性地进行优化; 例如, 在高度不确定性区域, 可能需要进一步丰富训练数据, 尤其是增强在这些区域的样本数量和样本多样性, 从而减少因数据缺乏而导致的预测误差。

输入数据 (激光雷达) 本身的数据质量, 尤其是近地面和机载激光雷达数据获取后很难进行大幅度优化。星载激光雷达数据则通过数据筛选 (Zhu 等, 2022)、光子重分类 (Zhao 等, 2023a)、定位纠正 (Wang 等, 2024a) 等方法提升冠层高度的提取精度。然而, 激光雷达数据衍生的特征变量选择是降低不确定性并提高模型性能的关键步骤之一。通过不确定性分析, 可发现对模型预测有较大影响的输入特征, 可能引入不必要噪声的输入特征。例如, 采用递归特征消除来剔除冗余或无关的变量, 能够有效提升模型的解释性和精度 (Gao 等, 2022a)。因机载或星载激光雷达数据并不能直观检测到胸径, 仅可获取高度, 且植被的生长也受到各种环境因素的影响, 通过多源数据融合 (如激光雷达和光学影像的结合), 可以补充单一数据源可能遗漏的信息, 降低模型的不确定性, 进而提高模型的估测精度 (Luo 等, 2017)。

模型方面, 对于简单参数模型 (如线性回归), 模型残差是模型不确定性的主要来源 (Chen 等, 2015a)。通过分析可能影响生物量估测精度的因子如地形、植被类型、遥感变量、样地的位置误差等, 将这些因子作为自变量, 模型残差作为因变量, 采用多项式回归方法开展不确定性分析研究, 发现残差与木材密度呈正相关, 因此将木材

密度作为分层因子，采用混合效应模型，模型验证 R^2 从0.38上升至0.75（Chen等，2015b）。而对于非参数模型，优化模型参数可以有效降低模型的不确定性，特别是在复杂的森林环境中。如使用集成学习（如随机森林或梯度提升方法），综合多个弱模型，提高对异质性数据的拟合能力（Campbell等，2021）。另外，在建模过程中引入不确定性估计（如预测区间或残差分析），可以量化模型的置信区间。

6 森林生物量估测模型的时空可迁移性

建立具有时间和空间尺度可迁移性的森林生物量估测模型已有一定的研究（Navarro等，2020；van Passel等，2020）。受建模变量及环境因素的影响，当前的森林生物量估测模型缺乏时空可迁移能力。要使模型具有可迁移性，要求建模变量不受外部环境因素差异的影响，而且不同区域环境因素的差异不影响建模变量与生物量之间的关系（Lu等，2016），但至今还没有普适性的森林生物量估测模型或方法。

6.1 森林生物量估测模型的时间尺度可迁移性

估测模型的时间尺度可迁移性指基于某个研究区样地和高度变量构建的生物量估测模型可直接用于同一研究区另一年份的生物量估测，不同年份的生物量估测值有相似的估测精度（Domingo等，2019）。模型的时间尺度可迁移性，使森林生物量的变化监测成为可能（Fekety等，2015；Navarro等，2020）。例如，使用2016年获取的高密度激光雷达数据建立的生物量模型被成功外推到2011年的数据，表明可迁移模型是减少实地工作量并准确估算两个不同日期森林属性的成功途径（Domingo等，2019）。随着激光雷达传感器的快速发展，多时相激光雷达数据的采集成本逐渐降低。虽然采集参数存在差异，如两次飞行的点云密度有差异，但点云密度的变化似乎不会影响森林生物量在样地尺度上的变化监测（Loh等，2022）。激光雷达数据衍生的变量的选择才是影响模型的关键。

6.2 森林生物量估测模型的空间尺度可迁移性

估测模型的空间可迁移性指基于某个研究区

样地和激光雷达数据构建的生物量估测模型，直接用于另一个研究区的生物量估测制图（Tompalski等，2019）。建模变量及方法的选择，不同研究区树种组成的差异，地形、气候条件等的差异会直接影响模型的空间可迁移性。Van Ewijk等（2020）和Tompalski等（2019）通过使用不同的建模方法（如随机森林，k-最近邻）在研究站点之间检验了不同的迁移场景，预测精度因建模方法和站点而异。使用更多变量的复杂算法会增加过度拟合局部条件的风险，从而在模型需要迁移到新环境时失去通用性（Werkowska等，2017）。如果环境相似，在一个研究区域建立的模型可以成功迁移到跨场景数据（Werkowska等，2017；Fekety等，2018）。近年来，研究如何建立基于机载激光雷达数据的通用模型来预测森林生物量逐渐获得重视（Feng等，2021；Lin等，2022）。这些模型试图通过整合来自各种环境条件的众多样地数据并减少对各个位置的模型系数的依赖来改善估算结果。此外，将外推区域的样本数据与基础数据一起纳入校准集，增强了所有建模方法和每个站点的生物量预测的可迁移性（van Ewijk等，2020）。由于生物量样地数据获取困难，需进一步研究如何有效地利用现有的生物量估测模型和外推区域少量的样本来建立新模型。在建立具有可迁移性的生物量估测模型时，需要综合考虑环境异质性、变量选择及建模方法的适用性。未来可考虑结合物理模型与机器学习，将物理过程与数据驱动方法相融合，有效整合环境影响因子。这种方法有望提高模型在不同环境中的适用性，并在减少样地数据需求方面取得突破。

7 结 语

激光雷达数据为森林生物量高精度估测提供了重要支撑。不同平台激光雷达数据的特性各异，如近地面激光雷达数据精度高但覆盖范围有限；机载激光雷达平衡了空间覆盖和分辨率；星载激光雷达则具有大范围监测能力，但难以全覆盖分布及数据质量相对较低。针对数据的局限性，需要探索多源激光雷达数据的有效整合及激光雷达数据与其他遥感数据的融合，进一步提升生物量估测的精度。

生物量估测建模方法从传统的多元回归，到复杂的机器学习和深度学习模型，以及将物理模

型与机器学习结合的混合模型, 各具优势与适用场景。多元回归模型简单易用, 但对数据的非线性关系捕捉不足; 机器学习模型如随机森林能够处理复杂的非线性关系, 但对样本数量及参数优化的需求较高; 深度学习如卷积神经网络在特征提取和模式识别中表现突出, 但对样本数量和计算资源的依赖较强。未来研究应关注建模方法的选择与优化, 特别是在不同空间尺度和森林类型下模型的适用性, 以及模型的不确定性分析和迁移性验证, 以提升模型的可靠性和普适性。生物量建模过程的优化是提升森林生物量估测精度的关键环节, 需要在建模过程中引入不确定性估计, 通过不确定性分析揭示和量化生物量建模过程中的误差来源, 从而为优化生物量估测建模过程提供依据。

志 谢 此次文献的整理由团队宋凌寒和赖熠婷协助, 在此表示衷心的感谢!

参考文献(References)

- Ahmed R, Siqueira P and Hensley S. 2013. A study of forest biomass estimates from lidar in the northern temperate forests of New England. *Remote Sensing of Environment*, 130: 121-135 [DOI: 10.1016/j.rse.2012.11.015]
- Almeida C T D, Galvão L S, de Oliveira Cruz e Aragão L E, Ometto J P H B, Jacon A D, de Souza Pereira F R, Sato L Y, Lopes A P, de Alencastro Graça P M L, de Jesus Silva C V, Ferreira-Ferreira J and Longo M. 2019. Combining lidar and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. *Remote Sensing of Environment*, 232: 111323 [DOI: 10.1016/j.rse.2019.111323]
- Anderson J E, Plourde L C, Martin M E, Braswell B H, Smith M L, Dubayah R O, Hofton M A and Blair J B. 2008. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. *Remote Sensing of Environment*, 112(4): 1856-1870 [DOI: 10.1016/j.rse.2007.09.009]
- Anderson R S and Bolstad P V. 2013. Estimating aboveground biomass and average annual wood biomass increment with airborne leaf-on and leaf-off lidar in great lakes forest types. *Northern Journal of Applied Forestry*, 30(1): 16-22 [DOI: 10.5849/njaf.12-015]
- Araza A, De Bruin S, Herold M, Quegan S, Labriere N, Rodriguez-Veiga P, Avitabile V, Santoro M, Mitchard E T A, Ryan C M, Phillips O L, Willcock S, Verbeeck H, Carreiras J, Hein L, Schelhaas M J, Pacheco-Pascagaza A M, Da Conceição Bispo P, Laurin G V, Vieilledent G, Slik F, Wijaya A, Lewis S L, Morel A, Liang J J, Sukhdeo H, Schepaschenko D, Cavlovic J, Gilani H and Lucas R. 2022. A comprehensive framework for assessing the accuracy and uncertainty of global above-ground biomass maps. *Remote Sensing of Environment*, 272: 112917 [DOI: 10.1016/j.rse.2022.112917]
- Aubry-Kientz M, Dutrieux R, Ferraz A, Saatchi S, Hamraz H, Williams J, Coomes D, Piboule A and Vincent G. 2019. A comparative assessment of the performance of individual tree crowns delineation algorithms from ALS data in tropical forests. *Remote Sensing*, 11(9): 1086 [DOI: 10.3390/rs11091086]
- Barrett F, McRoberts R E, Tomppo E, Cienciala E and Waser L T. 2016. A questionnaire-based review of the operational use of remotely sensed data by national forest inventories. *Remote Sensing of Environment*, 174: 279-289 [DOI: 10.1016/j.rse.2015.08.029]
- Berger A, Gschwantner T, McRoberts R E and Schadauer K. 2014. Effects of measurement errors on individual tree stem volume estimates for the Austrian national forest inventory. *Forest Science*, 60(1): 14-24 [DOI: 10.5849/forsci.12-164]
- Bouvier M, Durrieu S, Fournier R A, Saint-Geours N, Guyon D, Graue E and de Boissieu F. 2019. Influence of sampling design parameters on biomass predictions derived from airborne lidar data. *Canadian Journal of Remote Sensing*, 45(5): 650-672 [DOI: 10.1080/07038992.2019.1669013]
- Brede B, Calders K, Lau A, Raunonen P, Bartholomeus H M, Herold M and Kooistra L. 2019. Non-destructive tree volume estimation through quantitative structure modelling: comparing UAV laser scanning with terrestrial LIDAR. *Remote Sensing of Environment*, 233: 111355 [DOI: 10.1016/j.rse.2019.111355]
- Brede B, Terryn L, Barbier N, Bartholomeus H M, Bartolo R, Calders K, Derroire G, Krishna Moorthy S M, Lau A, Levick S R, Raunonen P, Verbeeck H, Wang D, Whiteside T, van der Zee J and Herold M. 2022. Non-destructive estimation of individual tree biomass: allometric models, terrestrial and UAV laser scanning. *Remote Sensing of Environment*, 280: 113180 [DOI: 10.1016/j.rse.2022.113180]
- Breidenbach J, Antón-Fernández C, Petersson H, McRoberts R E and Astrup R. 2014. Quantifying the model-related variability of biomass stock and change estimates in the Norwegian national forest inventory. *Forest Science*, 60(1): 25-33 [DOI: 10.5849/forsci.12-137]
- Bruggisser M, Hollaus M, Otepka J and Pfeifer N. 2020. Influence of ULS acquisition characteristics on tree stem parameter estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168: 28-40 [DOI: 10.1016/j.isprsjprs.2020.08.002]
- Cabo C, Del Pozo S, Rodríguez-González P, Ordóñez C and González-Aguilera D. 2018. Comparing terrestrial laser scanning (TLS) and wearable laser scanning (WLS) for individual tree modeling at plot level. *Remote Sensing*, 10(4): 540 [DOI: 10.3390/rs10040540]
- Calders K, Adams J, Armston J, Bartholomeus H, Bauwens S, Bentley L P, Chave J, Danson F M, Demol M, Disney M, Gaulton R, Krishna Moorthy S M, Levick S R, Saarinen N, Schaaf C, Stovall A, Terryn L, Wilkes P and Verbeeck H. 2020. Terrestrial laser

- scanning in forest ecology: expanding the horizon. *Remote Sensing of Environment*, 251: 112102 [DOI: 10.1016/j.rse.2020.112102]
- Campbell M J, Dennison P E, Kerr K L, Brewer S C and Anderegg W R L. 2021. Scaled biomass estimation in woodland ecosystems: testing the individual and combined capacities of satellite multi-spectral and lidar data. *Remote Sensing of Environment*, 262: 112511 [DOI: 10.1016/j.rse.2021.112511]
- Cao H Y, Zhang X W, Huang J, He T, Mao Y L and Lu Q R. 2023. System design and key technologies of terrestrial ecosystem carbon inventory satellite. *Chinese Space Science and Technology*, 43(6): 112-124 (曹海翊, 张新伟, 黄缙, 贺涛, 毛一岚, 卢清荣. 2023. 陆地生态系统碳监测卫星系统设计与技术创新. *中国空间科学技术*, 43(6): 112-124) [DOI: 10.16708/j.cnki.1000-758X.2023.0090]
- Cao L, Coops N, Hermosilla T, Innes J, Dai J S and She G H. 2014. Using small-footprint discrete and full-waveform airborne lidar metrics to estimate total biomass and biomass components in subtropical forests. *Remote Sensing*, 6(8): 7110-7135 [DOI: 10.3390/rs6087110]
- Cao L, Xu T, Shen X and She G H. 2016. Mapping biomass by integrating Landsat OLI and airborne LiDAR transect data in subtropical forests. *Journal of Remote Sensing (in Chinese)*, 20(4): 665-678 (曹林, 徐婷, 申鑫, 余光辉. 2016. 集成 Landsat OLI 和机载 LiDAR 条带数据的亚热带森林生物量制图. *遥感学报*, 20(4): 665-678) [DOI: 10.11834/jrs.20165210]
- Chang B T, Xiong H, Li Y, Pan D, Cui X D and Zhang W M. 2024. ALCSF: an adaptive and anti-noise filtering method for extracting ground and top of canopy from ICESat-2 LiDAR data along single tracks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 215: 80-98 [DOI: 10.1016/j.isprsjprs.2024.07.002]
- Chave J, Condit R, Aguilar S, Hernandez A, Lao S and Perez R. 2004. Error propagation and scaling for tropical forest biomass estimates. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 359(1443): 409-420 [DOI: 10.1098/rstb.2003.1425]
- Chen J H, Zhao D, Zheng Z J, Xu C, Pang Y and Zeng Y. 2024a. A clustering-based automatic registration of UAV and terrestrial LiDAR forest point clouds. *Computers and Electronics in Agriculture*, 217: 108648 [DOI: 10.1016/j.compag.2024.108648]
- Chen L, Ren C Y, Bao G D, Zhang B, Wang Z M, Liu M Y, Man W D and Liu J F. 2022. Improved object-based estimation of forest aboveground biomass by integrating LiDAR data from GEDI and ICESat-2 with multi-sensor images in a heterogeneous mountainous region. *Remote Sensing*, 14(12): 2743 [DOI: 10.3390/rs14122743]
- Chen Q, Laurin G V, Battles J J and Saah D. 2012. Integration of airborne lidar and vegetation types derived from aerial photography for mapping aboveground live biomass. *Remote Sensing of Environment*, 121: 108-117 [DOI: 10.1016/j.rse.2012.01.021]
- Chen Q, Laurin G V and Valentini R. 2015a. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: propagating errors from trees to plots to pixels. *Remote Sensing of Environment*, 160: 134-143 [DOI: 10.1016/j.rse.2015.01.009]
- Chen Q, Lu D S, Keller M, Dos-Santos M N, Bolfe E L, Feng Y Y and Wang C W. 2015b. Modeling and mapping agroforestry above-ground biomass in the Brazilian Amazon using airborne lidar data. *Remote Sensing*, 8(1): 21 [DOI: 10.3390/rs8010021]
- Chen S T, Nie S, Xi X H, Xia S B, Zhu F, Wang C and Zhu X X. 2024b. A novel multidimensional statistics denoising algorithm based on Gaussian mixture model for photon-counting LiDAR Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 13308-13323 [DOI: 10.1109/JSTARS.2024.3430470]
- Chen W J, Chen J and Cihlar J. 2000. An integrated terrestrial ecosystem carbon-budget model based on changes in disturbance, climate, and atmospheric chemistry. *Ecological Modelling*, 135(1): 55-79 [DOI: 10.1016/S0304-3800(00)00371-9]
- Chen Y Y, Li L W, Lu D S and Li D Q. 2018. Exploring bamboo forest aboveground biomass estimation using Sentinel-2 data. *Remote Sensing*, 11(1): 7 [DOI: 10.3390/rs11010007]
- Chi H, Sun G Q, Huang J L, Guo Z F, Ni W J and Fu A M. 2015. National forest aboveground biomass mapping from ICESat/GLAS Data and MODIS imagery in China. *Remote Sensing*, 7(5): 5534-5564 [DOI: 10.3390/rs70505534]
- Coops N C, Tompalski P, Goodbody T R H, Queinnec M, Luther J E, Bolton D K, White J C, Wulder M A, van Lier O R and Hermosilla T. 2021. Modelling lidar-derived estimates of forest attributes over space and time: a review of approaches and future trends. *Remote Sensing of Environment*, 260: 112477 [DOI: 10.1016/j.rse.2021.112477]
- Dai W X, Kan H Y, Tan R C, Yang B S, Guan Q F, Zhu N N, Xiao W and Dong Z. 2022. Multisource forest point cloud registration with semantic-guided keypoints and robust RANSAC mechanisms. *International Journal of Applied Earth Observation and Geoinformation*, 115: 103105 [DOI: 10.1016/j.jag.2022.103105]
- David R M, Rosser N J and Donoghue D N M. 2022. Improving above ground biomass estimates of Southern Africa dryland forests by combining Sentinel-1 SAR and Sentinel-2 multispectral imagery. *Remote Sensing of Environment*, 282: 113232 [DOI: 10.1016/j.rse.2022.113232]
- Demol M, Verbeeck H, Gielen B, Armston J, Burt A, Disney M, Duncanson L, Hackenberg J, Kükenbrink D, Lau A, Ploton P, Seudinen A, Stovall A, Takoudjou S M, Volkova L, Weston C, Wortel V and Calders K. 2022. Estimating forest above-ground biomass with terrestrial laser scanning: current status and future directions. *Methods in Ecology and Evolution*, 13(8): 1628-1639 [DOI: 10.1111/2041-210X.13906]
- Domingo D, Alonso R, Lamelas M T, Montealegre A L, Rodríguez F and de la Riva J. 2019. Temporal transferability of pine forest attributes modeling using low-density airborne laser scanning data. *Remote Sensing*, 11(3): 261 [DOI: 10.3390/rs11030261]
- Dong J C, Ni W J, Zhang Z Y and Sun G Q. 2021. Performance of ICESat-2 ATL08 product on the estimation of forest height by referencing to small footprint LiDAR data. *National Remote Sensing*

- Bulletin, 25(6): 1294-1307 (董佳臣, 倪文俭, 张志玉, 孙国清). 2021. ICESat-2 植被冠层高度和地表高程数据产品用于森林高度提取的效果评价. 遥感学报, 25(6): 1294-1307 [DOI: 10.11834/jrs.20219449]
- Dong P L and Chen Q. 2018. LiDAR Remote Sensing and Applications. Boca Raton: CRC Press [DOI: 10.4324/9781351233354]
- Dorado-Roda I, Pascual A, Godinho S, Silva C A, Botequim B, Rodríguez-González P, González-Ferreiro E and Guerra-Hernández J. 2021. Assessing the accuracy of GEDI Data for canopy height and aboveground biomass estimates in mediterranean forests. Remote Sensing, 13(12): 2279 [DOI: 10.3390/rs13122279]
- Drake J B, Knox R G, Dubayah R O, Clark D B, Condit R, Blair J B and Hofton M. 2003. Above-ground biomass estimation in closed canopy Neotropical forests using lidar remote sensing: factors affecting the generality of relationships. Global Ecology and Biogeography, 12(2): 147-159 [DOI: 10.1046/j.1466-822X.2003.00010.x]
- Du C Y, Fan W Y, Ma Y, Jin H I and Zhen Z. 2021. The effect of synergistic approaches of features and ensemble learning algorithms on aboveground biomass estimation of natural secondary forests based on ALS and Landsat8. Sensors, 21(17): 5974 [DOI: 10.3390/s21175974]
- Du L M, Pang Y, Ni W J, Liang X J, Li Z Y, Suarez J and Wei W. 2024. Forest terrain and canopy height estimation using stereo images and spaceborne LiDAR data from GF-7 satellite. Geo-Spatial Information Science, 27(3): 811-821 [DOI: 10.1080/10095020.2023.2249037]
- Du L M, Pang Y, Wang Q, Huang C Q, Bai Y, Chen D S, Lu W and Kong D. 2023. A LiDAR biomass index-based approach for tree- and plot-level biomass mapping over forest farms using 3D point clouds. Remote Sensing of Environment, 290: 113543 [DOI: 10.1016/j.rse.2023.113543]
- Du S L, Lindenbergh R, Ledoux H, Stoter J and Nan L L. 2019. AdTree: accurate, detailed, and automatic modelling of laser-scanned trees. Remote Sensing, 11(18): 2074 [DOI: 10.3390/rs11182074]
- Duanmu J L and Xing Y Q. 2020. Annular neighboring points distribution analysis: a novel PLS stem point cloud preprocessing algorithm for DBH estimation. Remote Sensing, 12(5): 808 [DOI: 10.3390/rs12050808]
- Duncanson L, Kellner J R, Armston J, Dubayah R, Minor D M, Hancock S, Healey S P, Patterson P L, Saarela S, Marselis S, Silva C E, Bruening J, Goetz S J, Tang H, Hofton M, Blair B, Luthcke S, Fatoyinbo L, Abernethy K, Alonso A, Andersen H E, Aplin P, Baker T R, Barbier N, Bastin J F, Biber P, Boeckx P, Bogaert J, Boschetti L, Boucher P B, Boyd D S, Burslem D F R P, Calvo-Rodríguez S, Chave J, Chazdon R L, Clark D B, Clark D A, Cohen W B, Coomes D A, Corona P, Cushman K C, Cutler M E J, Dalling J W, Dalponte M, Dash J, De-Miguel S, Deng S Q, Ellis P W, Erasmus B, Fekety P A, Fernandez-Landa A, Ferraz A, Fischer R, Fisher A G, García-Abril A, Gobakken T, Hacker J M, Heurich M, Hill R A, Hopkinson C, Huang H B, Hubbell S P, Hudak A T, Huth A, Imbach B, Jeffery K J, Katoh M, Kearsley E, Kenfack D, Kljun N, Knapp N, Král K, Krůček M, Labrière N, Lewis S L, Longo M, Lucas R M, Main R, Manzanera J A, Martínez R V, Mathieu R, Memiaghe H, Meyer V, Mendoza A M, Monerris A, Montesano P, Morsdorf F, Næsset E, Naidoo L, Nilus R, O'Brien M, Orwig D A, Papathanassiou K, Parker G, Philipson C, Phillips O L, Pisek J, Poulsen J R, Pretzsch H and Rüdiger C, Saatchi S, Sanchez-Azofeifa A, Sanchez-Lopez N, Scholes R, Silva C A, Simard M, Skidmore A, Stereńczak K, Tanase M, Torresan C, Valbuena R, Verbeeck H, Vrska T, Wessels K, White J C, White L J T, Zahabu E and Zraggen C. 2022. Aboveground biomass density models for NASA's global ecosystem dynamics investigation (GEDI) lidar mission. Remote Sensing of Environment, 270: 112845 [DOI: 10.1016/j.rse.2021.112845]
- Duncanson L, Neuenschwander A, Hancock S, Thomas N, Fatoyinbo T, Simard M, Silva C A, Armston J, Luthcke S B, Hofton M, Kellner J R and Dubayah R. 2020. Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. Remote Sensing of Environment, 242: 111779 [DOI: 10.1016/j.rse.2020.111779]
- Duncanson L I, Niemann K O and Wulder M A. 2010. Estimating forest canopy height and terrain relief from GLAS waveform metrics. Remote Sensing of Environment, 114(1): 138-154 [DOI: 10.1016/j.rse.2009.08.018]
- Ene L T, Næsset E, Gobakken T, Mauya E W, Bollandås O M, Gregoire T G, Ståhl G and Zahabu E. 2016. Large-scale estimation of aboveground biomass in miombo woodlands using airborne laser scanning and national forest inventory data. Remote Sensing of Environment, 186: 626-636 [DOI: 10.1016/j.rse.2016.09.006]
- Erb K H, Kastner T, Plutzer C, Bais A L S, Carvalhais N, Fetzl T, Gingrich S, Haberl H, Lauk C, Niedertscheider M, Pongratz J, Thurner M and Luyssaert S. 2018. Unexpectedly large impact of forest management and grazing on global vegetation biomass. Nature, 553(7686): 73-76 [DOI: 10.1038/nature25138]
- Fan G P, Nan L L, Dong Y Q, Su X H and Chen F X. 2020. AdQSM: a new method for estimating above-ground biomass from TLS point clouds. Remote Sensing, 12(18): 3089 [DOI: 10.3390/rs12183089]
- Fang G S, Fang L M, Yang L B and Wu D S. 2022. Comparison of variable selection methods among dominant tree species in different regions on forest stock volume estimation. Forests, 13(5): 787 [DOI: 10.3390/f13050787]
- Fekety P A, Falkowski M J and Hudak A T. 2015. Temporal transferability of Lidar-based imputation of forest inventory attributes. Canadian Journal of Forest Research, 45(4): 422-435 [DOI: 10.1139/cjfr2014-0405]
- Fekety P A, Falkowski M J, Hudak A T, Jain T B and Evans J S. 2018. Transferability of lidar-derived basal area and stem density models within a northern Idaho ecoregion. Canadian Journal of Remote Sensing, 44(2): 131-143 [DOI: 10.1080/07038992.2018.1461557]
- Fekry R, Yao W, Cao L and Shen X. 2022. Ground-based/UAV-LiDAR

- data fusion for quantitative structure modeling and tree parameter retrieval in subtropical planted forest. *Forest Ecosystems*, 9: 100065 [DOI: 10.1016/j.fecs.2022.100065]
- Feng H N, Chen Q, Hu Y M, Du Z G, Lin G T, Wang C W and Huang Y J. 2021. Estimation of forest aboveground biomass by using mixed-effects model. *International Journal of Remote Sensing*, 42 (22): 8675-8690 [DOI: 10.1080/01431161.2021.1984611]
- Feng Y Y, Lu D S, Chen Q, Keller M, Moran E, Dos-Santos M N, Bolfe E L and Batistella M. 2017. Examining effective use of data sources and modeling algorithms for improving biomass estimation in a moist tropical forest of the Brazilian Amazon. *International Journal of Digital Earth*, 10(10): 996-1016 [DOI: 10.1080/17538947.2017.1301581]
- Frazer G W, Magnussen S, Wulder M A and Niemann K O. 2011. Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. *Remote Sensing of Environment*, 115(2): 636-649 [DOI: 10.1016/j.rse.2010.10.008]
- Gao L H, Chai G Q and Zhang X L. 2022a. Above-ground biomass estimation of plantation with different tree species using airborne lidar and hyperspectral data. *Remote Sensing*, 14(11): 2568 [DOI: 10.3390/RS14112568]
- Gao S J, Li Y, Zhu J J, Fu H Q and Zhou C. 2022b. Retrieving forest canopy height from ICESat-2 Data by an improved DRAGANN filtering method and canopy top photons classification. *IEEE Geoscience and Remote Sensing Letters*, 19: 2505505 [DOI: 10.1109/LGRS.2022.3183683]
- Gao Y K, Lu D S, Li G Y, Wang G X, Chen Q, Liu L J and Li D Q. 2018. Comparative analysis of modeling algorithms for forest aboveground biomass estimation in a subtropical region. *Remote Sensing*, 10(4): 627 [DOI: 10.3390/rs10040627]
- Ghosh S M and Behera M D. 2021. Aboveground biomass estimates of tropical mangrove forest using sentinel-1 SAR coherence data - the superiority of deep learning over a semi-empirical model. *Computers and Geosciences*, 150: 104737 [DOI: 10.1016/j.cageo.2021.104737]
- Goldbergs G, Levick S R, Lawes M and Edwards A. 2018. Hierarchical integration of individual tree and area-based approaches for savanna biomass uncertainty estimation from airborne LiDAR. *Remote Sensing of Environment*, 205: 141-150 [DOI: 10.1016/j.rse.2017.11.010]
- Gong J Y and Li Y S. 2022. Can quantitative remote sensing and machine learning be integrated? *Earth Science*, 47(10): 3911-3912 (龚健雅, 李彦胜. 2022. 定量遥感与机器学习能够融合吗? *地球科学*, 47(10): 3911-3912) [DOI: 10.3799/dqkx.2022.861]
- Gonzalez P, Asner G P, Battles J J, Lefsky M A, Waring K M and Palace M. 2010. Forest carbon densities and uncertainties from lidar, quickbird, and field measurements in California. *Remote Sensing of Environment*, 114(7): 1561-1575 [DOI: 10.1016/j.rse.2010.02.011]
- Grafström A and Ringvall A H. 2013. Improving forest field inventories by using remote sensing data in novel sampling designs. *Canadian Journal of Forest Research*, 43(11): 1015-1022 [DOI: 10.1139/cjfr-2013-0123]
- Guan H C, Su Y J, Hu T Y, Wang R, Ma Q, Yang Q L, Sun X L, Li Y M, Jin S C, Zhang J, Ma Q, Liu M, Wu F Y and Guo Q H. 2020. A novel framework to automatically fuse multiplatform LiDAR data in forest environments based on tree locations. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3): 2165-2177 [DOI: 10.1109/TGRS.2019.2953654]
- Guerra-Hernández J, Narine L L, Pascual A, Gonzalez-Ferreiro E, Botequim B, Malambo L, Neuenschwander A, Popescu S C and Godinho S. 2022. Aboveground biomass mapping by integrating ICESat-2, SENTINEL-1, SENTINEL-2, ALOS2/PALSAR2, and topographic information in Mediterranean forests. *GIScience and Remote Sensing*, 59(1): 1509-1533 [DOI: 10.1080/15481603.2022.2115599]
- Guo Q H, Su Y J, Hu T Y, Guan H C, Jin S C, Zhang J, Zhao X X, Xu K X, Wei D J, Kelly M and Coops N C. 2021. Lidar boosts 3D ecological observations and modelings: a review and perspective. *IEEE Geoscience and Remote Sensing Magazine*, 9(1): 232-257 [DOI: 10.1109/MGRS.2020.3032713]
- Guo Q H, Su Y J, Hu T Y and Liu J. 2018. *LiDAR Principles, Processing and Applications in Forest Ecology*. Beijing: Higher Education Press (郭庆华, 苏艳军, 胡天宇, 刘瑾. 2018. 激光雷达森林生态应用: 理论、方法及实例. 北京: 高等教育出版社)
- Hackenberg J, Spiecker H, Calders K, Disney M and Raunonen P. 2015. Simpletree—an efficient open source tool to build tree models from TLS clouds. *Forests*, 6(11): 4245-4294 [DOI: 10.3390/f6114245]
- Hancock S, Armston J, Hofton M, Sun X L, Tang H, Duncanson L I, Kellner J R and Dubayah R. 2019. The GEDI simulator: a large-footprint waveform lidar simulator for calibration and validation of spaceborne missions. *Earth and Space Science*, 6(2): 294-310 [DOI: 10.1029/2018EA000506]
- Heiskanen J, Adhikari H, Piironen R, Packalen P and Pellikka P K E. 2019. Do airborne laser scanning biomass prediction models benefit from landsat time series, hyperspectral data or forest classification in tropical mosaic landscapes? *International Journal of Applied Earth Observation and Geoinformation*, 81: 176-185 [DOI: 10.1016/j.jag.2019.05.017]
- Hernández-Stefanoni J L, Reyes-Palomeque G, Castillo-Santiago M Á, George-Chacón S P, Huechacona-Ruiz A H, Tun-Dzul F, Rondon-Rivera D and Dupuy J M. 2018. Effects of sample plot size and GPS location errors on aboveground biomass estimates from LiDAR in tropical dry forests. *Remote Sensing*, 10(10): 1586 [DOI: 10.3390/rs10101586]
- Huang K B, Pang Y, Shu Q T and Fu T. 2013. Aboveground forest biomass estimation using ICESat GLAS in Yunnan, China. *Journal of Remote Sensing (in Chinese)*, 17(1): 165-179 (黄克标, 庞勇, 舒清态, 付甜. 2013. 基于 ICESat GLAS 的云南省森林地上生物量反演. *遥感学报*, 17(1): 165-179) [DOI: 10.11834/jrs.20130436]
- Hunter M O, Keller M, Victoria D and Morton D C. 2013. Tree height and tropical forest biomass estimation. *Biogeosciences*, 10(12):

- 8385-8399 [DOI: 10.5194/bg-10-8385-2013]
- Huo L N and Zhang X L. 2019. A new method of equiangular sectorial voxelization of single-scan terrestrial laser scanning data and its applications in forest defoliation estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151: 302-312 [DOI: 10.1016/j.isprsjprs.2019.03.018]
- Jiang F G, Deng M L, Tang J, Fu L Y and Sun H. 2022. Integrating spaceborne LiDAR and Sentinel-2 images to estimate forest aboveground biomass in Northern China. *Carbon Balance and Management*, 17(1): 12 [DOI: 10.1186/s13021-022-00212-y]
- Jiang X D, Li D Q, Li G Y and Lu D S. 2023. Eucalyptus carbon stock estimation in subtropical regions with the modeling strategy of sample plots – airborne LiDAR – Landsat time series data. *Forest Ecosystems*, 10: 100149 [DOI: 10.1016/j.fecs.2023.100149]
- Jiang X D, Li G Y, Lu D S, Chen E X and Wei X L. 2020a. Stratification-based forest aboveground biomass estimation in a subtropical region using airborne lidar data. *Remote Sensing*, 12(7): 1101 [DOI: 10.3390/rs12071101]
- Jiang X D, Li G Y, Lu D S, Moran E and Batistella M. 2020b. Modeling forest aboveground carbon density in the Brazilian Amazon with integration of MODIS and airborne LiDAR Data. *Remote Sensing*, 12(20): 3330 [DOI: 10.3390/rs12203330]
- Jurjević L, Liang X L, Gašparović M and Balenović I. 2020. Is field-measured tree height as reliable as believed – Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169: 227-241 [DOI: 10.1016/j.isprsjprs.2020.09.014]
- Kanmegne Tamga D, Latifi H, Ullmann T, Baumhauer R, Bayala J and Thiel M. 2022. Estimation of aboveground biomass in agroforestry systems over three climatic regions in West Africa using Sentinel-1, Sentinel-2, ALOS, and GEDI data. *Sensors*, 23(1): 349 [DOI: 10.3390/s23010349]
- Keller M. 2007. Revised method for forest canopy height estimation from Geoscience Laser Altimeter System waveforms. *Journal of Applied Remote Sensing*, 1(1): 013537 [DOI: 10.1117/1.2795724]
- Kotivuori E, Maltamo M, Korhonen L and Packalen P. 2018. Calibration of nationwide airborne laser scanning based stem volume models. *Remote Sensing of Environment*, 210: 179-192 [DOI: 10.1016/j.rse.2018.02.069].
- Landsberg J J, Waring R H and Coops N C. 2003. Performance of the forest productivity model 3-PG applied to a wide range of forest types. *Forest Ecology and Management*, 172(2/3): 199-214 [DOI: 10.1016/S0378-1127(01)00804-0]
- Lang N, Kalischek N, Armston J, Schindler K, Dubayah R and Wegner J D. 2022. Global canopy height regression and uncertainty estimation from GEDI LIDAR waveforms with deep ensembles. *Remote Sensing of Environment*, 268: 112760 [DOI: 10.1016/j.rse.2021.112760]
- Laurin G V, Chen Q, Lindsell J A, Coomes D A, Frate F D, Guerriero L, Pirotti F and Valentini R. 2014. Above ground biomass estimation in an African tropical forest with LiDAR and hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 89: 49-58 [DOI: 10.1016/j.isprsjprs.2014.01.001]
- Lefsky M A. 2010. A global forest canopy height map from the moderate resolution imaging spectroradiometer and the geoscience laser altimeter system. *Geophysical Research Letters*, 37(15): L15401 [DOI: 10.1029/2010GL043622]
- Lefsky M A, Harding D J, Keller M, Cohen W B, Carabajal C C, Del Bom Espirito-Santo F, Hunter M O and De Oliveira RJr. 2005. Estimates of forest canopy height and aboveground biomass using ICESat. *Geophysical Research Letters*, 32(22): L22S02 [DOI: 10.1029/2005GL023971]
- Le Toan T, Quegan S, Davidson M W J, Balzter H, Paillou P, Papathanassiou K, Plummer S, Rocca F, Saatchi S, Shugart H and Ulander L. 2011. The BIOMASS mission: mapping global forest biomass to better understand the terrestrial carbon cycle. *Remote Sensing of Environment*, 115(11): 2850-2860 [DOI: 10.1016/j.rse.2011.03.020]
- Li G Y, Tang X M, Chen J Y, Yao J Q, Liu Z, Gao X M, Zou Z Q and Zhou X Q. 2021. Processing and preliminary accuracy validation of the GF-7 satellite laser altimetry data. *Acta Geodaetica et Cartographica Sinica*, 50(10): 1338-1348 (李国元, 唐新明, 陈继溢, 么嘉棋, 刘诏, 高小明, 左志强, 周晓青. 2021. 高分七号卫星激光测高数据处理与精度初步验证. *测绘学报*, 50(10): 1338-1348) [DOI: 10.11947/j.AGCS.2021.20210025]
- 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]
- Li Y C, Li C, Li M Y and Liu Z Z. 2019. Influence of variable selection and forest type on forest aboveground biomass estimation using machine learning algorithms. *Forests*, 10(12): 1073 [DOI: 10.3390/f10121073]
- Li Y H, Li G Y, Wang S R and Lu D S. 2024a. Retrieval of Chinese fir tree parameters under different understory conditions with the integration of handheld and airborne Lidar data. *Geo-Spatial Information Science*, 1-22 [DOI: 10.1080/10095020.2024.2439399]
- Li Y S, Lu D S, Lu Y G and Li G Y. 2024b. Examining the impact of topography and vegetation on existing forest canopy height products from ICESat-2 ATLAS/GEDI data. *Remote Sensing*, 16(19): 3650 [DOI: 10.3390/rs16193650]
- Li Z Y, Liu Q W and Pang Y. 2016. Review on forest parameters inversion using LiDAR. *Journal of Remote Sensing (in Chinese)*, 20(5): 1138-1150 (李增元, 刘清旺, 庞勇. 2016. 激光雷达森林参数反演研究进展. *遥感学报*, 20(5): 1138-1150) [DOI: 10.11834/jrs.20165130]
- 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. IS-

- PRS Journal of Photogrammetry and Remote Sensing, 144: 137-179 [DOI: 10.1016/j.isprsjprs.2018.06.021]
- Liang X L, Yao H Y, Qi H W and Wang X C. 2024. Forest in situ observations through a fully automated under-canopy unmanned aerial vehicle. *Geo-spatial Information Science*, 27(4): 983-999 [DOI: 10.1080/10095020.2024.2322765]
- Liao K, Li Y H, Zou B Z, Li D Q and Lu D S. 2022. Examining the role of UAV Lidar data in improving tree volume calculation accuracy. *Remote Sensing*, 14(17): 4410 [DOI: 10.3390/rs14174410]
- Lin W K, Lu Y G, Li G Y, Jiang X D and Lu D S. 2022. A comparative analysis of modeling approaches and canopy height-based data sources for mapping forest growing stock volume in a northern subtropical ecosystem of China. *GIScience and Remote Sensing*, 59(1): 568-589 [DOI: 10.1080/15481603.2022.2044139]
- Liu A B, Cheng X and Chen Z Q. 2021a. Performance evaluation of GEDI and ICESat-2 laser altimeter data for terrain and canopy height retrievals. *Remote Sensing of Environment*, 264: 112571 [DOI: 10.1016/j.rse.2021.112571]
- Liu K, Shen X, Cao L, Wang G B and Cao F L. 2018. Estimating forest structural attributes using UAV-LiDAR data in Ginkgo plantations. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146: 465-482 [DOI: 10.1016/j.isprsjprs.2018.11.001].
- Liu Q W, Wang J L, Ma W F, Zhang J P, Deng Y C, Shao D J, Xu D F and Liu Y C. 2021b. Target-free ULS-TLS point-cloud registration for alpine forest lands. *Computers and Electronics in Agriculture*, 190: 106460 [DOI: 10.1016/j.compag.2021.106460]
- Liu X Q, Su Y J, Hu T Y, Yang Q L, Liu B B, Deng Y F, Tang H, Tang Z Y, Fang J Y and Guo Q H. 2022. Neural network guided interpolation for mapping canopy height of China's forests by integrating GEDI and ICESat-2 data. *Remote Sensing of Environment*, 269: 112844 [DOI: 10.1016/j.rse.2021.112844]
- Loh H Y, James D, Ioki K, Wong W V C, Tsuyuki S and Phua M H. 2022. Estimating aboveground biomass changes in a human-modified tropical montane forest of Borneo using multi-temporal airborne LiDAR data. *Remote Sensing Applications: Society and Environment*, 28: 100821 [DOI: 10.1016/j.rsase.2022.100821]
- Longo M, Keller M, dos-Santos M N, Leitold V, Pinagé E R, Baccini A, Saatchi S, Nogueira E M, Batistella M and Morton D C. 2016. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. *Global Biogeochemical Cycles*, 30(11): 1639-1660 [DOI: 10.1002/2016GB005465]
- Lu D. 2005. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. *International Journal of Remote Sensing*, 26(12): 2509-2525 [DOI: 10.1080/01431160500142145]
- Lu D S. 2006. The potential and challenge of remote sensing - based biomass estimation. *International Journal of Remote Sensing*, 27(7): 1297-1328 [DOI: 10.1080/01431160500486732]
- Lu D S, Chen Q, Wang G X, Liu L J, Li G Y and Moran E. 2016. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth*, 9(1): 63-105 [DOI: 10.1080/17538947.2014.990526]
- Lu D S, Chen Q, Wang G X, Moran E, Batistella M, Zhang M Z, Laurin G V and Saah D. 2012. Aboveground forest biomass estimation with Landsat and LiDAR data and uncertainty analysis of the estimates. *International Journal of Forestry Research*, 2012: 436537 [DOI: 10.1155/2012/436537]
- Lu D S and Jiang X D. 2024. A brief overview and perspective of using airborne lidar data for forest biomass estimation. *International Journal of Image and Data Fusion*, 15(1): 1-24 [DOI: 10.1080/19479832.2024.2309615]
- Luo S Z, Wang C, Xi X H, Pan F F, Peng D L, Zou J, Nie S and Qin H M. 2017. Fusion of airborne lidar data and hyperspectral imagery for aboveground and belowground forest biomass estimation. *Ecological Indicators*, 73: 378-387 [DOI: 10.1016/j.ecolind.2016.10.001]
- Marchesan J, Alba E, Schuh M S, Favarin J A S, Fantinel R A, Marchesan L and Pereira R S. 2023. Aboveground biomass stock and change estimation in amazon rainforest using airborne light detection and ranging, multispectral data, and machine learning algorithms. *Journal of Applied Remote Sensing*, 17(2): 024509 [DOI: 10.1117/1.JRS.17.024509]
- Mareya H T, Tagwireyi P, Ndaimani H, Gara T W and Gwenzi D. 2018. Estimating tree crown area and aboveground biomass in miombo woodlands from high-resolution RGB-only imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(3): 868-875 [DOI: 10.1109/JSTARS.2018.2799386]
- Martin-Ducup O, Mofack G, Wang D, Raunonen P, Ploton P, Sonké B, Barbier N, Couteron P and Pélissier R. 2021. Evaluation of automated pipelines for tree and plot metric estimation from TLS data in tropical forest areas. *Annals of Botany*, 128(6): 753-766 [DOI: 10.1093/aob/mcab051]
- McRoberts R E and Westfall J A. 2014. Effects of uncertainty in model predictions of individual tree volume on large area volume estimates. *Forest Science*, 60(1): 34-42 [DOI: 10.5849/forsci.12-141]
- Meng G, Zhao D, Xu C, Chen J H, Li X W, Zheng Z J and Zeng Y. 2024. Forest aboveground biomass estimation combining ICESat-2 and GEDI spaceborne LiDAR data. *National Remote Sensing Bulletin*, 28(6): 1632-1647 (孟鸽, 赵丹, 许聪, 陈俊华, 李秀纹, 郑朝菊, 曾源. 2024. 联合 ICESat-2 和 GEDI 星载激光雷达数据的森林地上生物量估算. *遥感学报*, 28(6): 1632-1647) [DOI: 10.11834/jrs.20222120]
- Molina P X, Asner G P, Farjas Abadía M, Ojeda Manrique J C, Sánchez Díez L A and Valencia R. 2015. Spatially-explicit testing of a general aboveground carbon density estimation model in a western Amazonian forest using airborne LiDAR. *Remote Sensing*, 8(1): 9 [DOI: 10.3390/rs8010009]
- Narine L L, Popescu S C and Malambo L. 2019. Synergy of ICESat-2 and Landsat for mapping forest aboveground biomass with deep learning. *Remote Sensing*, 11(12): 1503 [DOI: 10.3390/rs11121503]
- Narine L L, Popescu S C and Malambo L. 2020. Using ICESat-2 to estimate and map forest aboveground biomass: a first example. *Remote Sensing*, 12(11): 1824 [DOI: 10.3390/rs12111824]

- Navarro J A, Tomé J L, Marino E, Guillén-Climent M L, Fernández-Landa A. 2020. Assessing the transferability of airborne laser scanning and digital aerial photogrammetry derived growing stock volume models. *International Journal of Applied Earth Observation and Geoinformation*, 91: 102135 [DOI: 10.1016/j.jag.2020.102135]
- Nelson R, Margolis H, Montesano P, Sun G Q, Cook B, Corp L, Andersen H E, deJong B, Pellat F P, Fickel T, Kauffman J and Pringley S. 2017. Lidar-based estimates of aboveground biomass in the continental US and Mexico using ground, airborne, and satellite observations. *Remote Sensing of Environment*, 188: 127-140 [DOI: 10.1016/j.rse.2016.10.038]
- Neuenschwander A, Guenther E, White J C, Duncanson L and Montesano P. 2020. Validation of ICESat-2 terrain and canopy heights in boreal forests. *Remote Sensing of Environment*, 251: 112110 [DOI: 10.1016/j.rse.2020.112110]
- Neuenschwander A and Pitts K. 2019. The ATL08 land and vegetation product for the ICESat-2 mission. *Remote Sensing of Environment*, 221: 247-259 [DOI: 10.1016/j.rse.2018.11.005]
- Nguyen T H, Jones S, Soto-Berelov M, Haywood A and Hislop S. 2019. Landsat time-series for estimating forest aboveground biomass and its dynamics across space and time: a review. *Remote Sensing*, 12(1): 98 [DOI: 10.3390/rs12010098]
- Ni W J, Zhang Z Y and Sun G Q. 2021. Assessment of slope-adaptive metrics of GEDI waveforms for estimations of forest aboveground biomass over mountainous areas. *Journal of Remote Sensing*, 2021: 9805364 [DOI: 10.34133/2021/9805364]
- Nie S, Wang C, Zeng H C, Xi X H and Li G C. 2017. Above-ground biomass estimation using airborne discrete-return and full-waveform LiDAR data in a coniferous forest. *Ecological Indicators*, 78: 221-228 [DOI: 10.1016/j.ecolind.2017.02.045]
- Oehmcke S, Li L, Trepekli K, Revenga J C, Nord-Larsen T, Gieseke F and Igel C. 2024. Deep point cloud regression for above-ground forest biomass estimation from airborne LiDAR. *Remote Sensing of Environment*, 302: 113968 [DOI: 10.1016/j.rse.2023.113968]
- Pang S Y, Li G Y, Jiang X D, Chen Y L, Lu Y G and Lu D S. 2022. Retrieval of forest canopy height in a mountainous region with ICESat-2 ATLAS. *Forest Ecosystems*, 9: 100046 [DOI: 10.1016/j.feecs.2022.100046]
- Pang Y, Li Z Y, Chen B W and Liang X J. 2019. Status and development of spaceborne lidar applications in forestry. *Aerospace Shanghai*, 36(3): 20-27 (庞勇, 李增元, 陈博伟, 梁晓军. 2019. 星载激光雷达森林探测进展及趋势. 上海航天, 36(3): 20-27) [DOI: 10.19328/j.cnki.1006-1630.2019.03.003]
- Pascual A, Guerra-Hernández J, Armston J, Minor D M, Duncanson L I, May P B, Kellner J R and Dubayah R. 2023. Assessing the performance of NASA's GEDI L4A footprint aboveground biomass density models using national forest inventory and airborne laser scanning data in Mediterranean forest ecosystems. *Forest Ecology and Management*, 538: 120975. [DOI: 10.1016/j.foreco.2023.120975]
- Pathak J, Wikner A, Fussell R, Chandra S, Hunt B R, Girvan M and Ott E. 2018. Hybrid forecasting of chaotic processes: using machine learning in conjunction with a knowledge-based model. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 28(4): 041101 [DOI: 10.1063/1.5028373]
- Phillips D L, Brown S L, Schroeder P E and Birdsey R A. 2000. Toward error analysis of large-scale forest carbon budgets. *Global Ecology and Biogeography*, 9(4): 305-313 [DOI: 10.1046/j.1365-2699.2000.00197.x]
- Phua M H, Hue S W, Ioki K, Hashim M, Bidin K, Musta B, Suleiman M, Yap S W and Maycock C R. 2016. Estimating logged-over lowland rainforest aboveground biomass in Sabah, Malaysia using airborne LiDAR data. *Terrestrial, Atmospheric and Oceanic Sciences*, 27(4): 481 [DOI: 10.3319/TAO.2016.01.06.02(ISRS)]
- Piao S L, He Y, Wang X H and Chen F H. 2022. Estimation of China's terrestrial ecosystem carbon sink: methods, progress and prospects. *Science China Earth Sciences*, 65(4): 641-651 (朴世龙, 何悦, 王旭辉, 陈发虎. 2022. 中国陆地生态系统碳汇估算: 方法、进展、展望. 中国科学: 地球科学, 52(6): 1010-1020) [DOI: 10.1007/s11430-021-9892-6]
- Potapov P, Li X Y, Hernandez-Serna A, Tyukavina A, Hansen M C, Kommareddy A, Pickens A, Turubanova S, Tang H, Silva C E, Armston J, Dubayah R, Blair J B and Hofton M. 2021. Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sensing of Environment*, 253: 112165 [DOI: 10.1016/j.rse.2020.112165]
- Puliti S, Saarela S, Gobakken T, Ståhl G and Næsset E. 2018. Combining UAV and Sentinel-2 auxiliary data for forest growing stock volume estimation through hierarchical model-based inference. *Remote Sensing of Environment*, 204: 485-497 [DOI: 10.1016/j.rse.2017.10.007]
- Qi W L, Saarela S, Armston J, Ståhl G and Dubayah R. 2019. Forest biomass estimation over three distinct forest types using TanDEM-X InSAR data and simulated GEDI lidar data. *Remote Sensing of Environment*, 232: 111283 [DOI: 10.1016/j.rse.2019.111283]
- Qi Y Q, Coops N C, Daniels L D and Butson C R. 2022. Comparing tree attributes derived from quantitative structure models based on drone and mobile laser scanning point clouds across varying canopy cover conditions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 192: 49-65 [DOI: 10.1016/j.isprsjprs.2022.07.021]
- Reichstein M, Camps-Valls G, Stevens B, Jung M, Denzler J, Carvalhais N and Prabhat. 2019. Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743): 195-204 [DOI: 10.1038/s41586-019-0912-1]
- Rex F E, Silva C A, Dalla Corte A P, Klauberger C, Mohan M, Cardil A, da Silva V S, de Almeida D R A, Garcia M, Broadbent E N, Valbuena R, Stoddart J, Merrick T and Hudak A T. 2020. Comparison of statistical modelling approaches for estimating tropical forest aboveground biomass stock and reporting their changes in low-intensity logging areas using multi-temporal lidar data. *Remote Sensing*, 12(9): 1498 [DOI: 10.3390/rs12091498]
- Roussel J R, Caspersen J, Béland M, Thomas S and Achim A. 2017. Removing bias from LiDAR-based estimates of canopy height:

- accounting for the effects of pulse density and footprint size. *Remote Sensing of Environment*, 198: 1-16 [DOI: 10.1016/j.rse.2017.05.032].
- Saarela S, Wästlund A, Holmström E, Mensah A A, Holm S, Nilsson M, Fridman J and Ståhl G. 2020. Mapping aboveground biomass and its prediction uncertainty using LiDAR and field data, accounting for tree-level allometric and LiDAR model errors. *Forest Ecosystems*, 7(1): 43 [DOI: 10.1186/s40663-020-00245-0]
- Salas-Eljatib C, Mehtätalo L, Gregoire T G, Soto D P and Vargas-Gaete R. 2021. Growth equations in forest research: mathematical basis and model similarities. *Current Forestry Reports*, 7(4): 230-244 [DOI: 10.1007/s40725-021-00145-8]
- Seidl R, Rammer W, Scheller R M and Spies T A. 2012. An individual-based process model to simulate landscape-scale forest ecosystem dynamics. *Ecological Modelling*, 231: 87-100 [DOI: 10.1016/j.ecolmodel.2012.02.015]
- Shen C P, Appling A P, Gentine P, Bandai T, Gupta H, Tartakovsky A, Baity-Jesi M, Fenicia F, Kifer D, Li L, Liu X F, Ren W, Zheng Y, Harman C J, Clark M, Farthing M, Feng D P, Kumar P, Aboelyazeed D, Rahmani F, Song Y L, Beck H E, Bindas T, Dwivedi D, Fang K, Höge M, Rackauckas C, Mohanty B, Roy T, Xu C G and Lawson K. 2023. Differentiable modelling to unify machine learning and physical models for geosciences. *Nature Reviews Earth and Environment*, 4: 552-567 [DOI: 10.1038/s43017-023-00450-9]
- Shen H F and Zhang L P. 2023. Mechanism-learning coupling paradigms for parameter inversion and simulation in earth surface systems. *Science China Earth Sciences*, 66(3): 568-582 (沈焕锋, 张良培. 2023. 地球表层特征参量反演与模拟的机理-学习耦合范式. *中国科学: 地球科学*, 53(3): 546-560) [DOI: 10.1007/s11430-022-9999-9]
- Silveira E M O, Silva S H G, Acerbi-Junior F W, Carvalho M C, Carvalho L M T, Scolforo J R S and Wulder M A. 2019. Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. *International Journal of Applied Earth Observation and Geoinformation*, 78: 175-188 [DOI: 10.1016/j.jag.2019.02.004]
- Singhal J, Srivastava G, Reddy C S, Rajashekar G, Jha C S, Rao P V N, Reddy G R and Roy P S. 2021. Assessment of carbon stock at tree level using terrestrial laser scanning vs. traditional methods in tropical forest, India. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 5064-5071 [DOI: 10.1109/JSTARS.2021.3076195]
- Stefanczak K, Laurin G V, Chirici G, Coomes D A, Dalponte M, Latifi H and Puletti N. 2020. Global airborne laser scanning data providers database (GlobALS)—a new tool for monitoring ecosystems and biodiversity. *Remote Sensing*, 12(11): 1877 [DOI: 10.3390/rs12111877].
- Sun G, Ranson K, Kimes D, Blair J and Kovacs K. 2008. Forest vertical structure from GLAS: an evaluation using LVIS and SRTM data. *Remote Sensing of Environment*, 112(1): 107-117 [DOI: 10.1016/j.rse.2006.09.036]
- Sun X Y, Li G Y, Wu Q Q, Ruan J Y, Li D Q and Lu D S. 2024. Mapping forest carbon stock distribution in a subtropical region with the integration of airborne LiDAR and Sentinel-2 data. *Remote Sensing*, 16(20): 3847 [DOI: 10.3390/rs16203847].
- Sun Y S, Jin X J, Pukkala T and Li F R. 2022. Predicting individual tree diameter of larch (*Larix olgensis*) from UAV-lidar data using six different algorithms. *Remote Sensing*, 14(5): 1125 [DOI: 10.3390/rs14051125]
- Talebiesfandarani S and Shamsoddini A. 2022. Global-scale biomass estimation based on machine learning and deep learning methods. *Remote Sensing Applications: Society and Environment*, 28: 100868 [DOI: 10.1016/j.rsase.2022.100868]
- Tang X M, Xie J F, Mo F, Dou X H, Li X, Li S N, Li S, Huang G H, Fu X K, Liu R, Zhu G B, Ouyang S D, Tang H Z and Chen H. 2021. GF-7 dual-beam laser altimeter on-orbit geometric calibration and test verification. *Acta Geodaetica et Cartographica Sinica*, 50(3): 384-395 (唐新明, 谢俊峰, 莫凡, 窦显辉, 李新, 李少宁, 李松, 黄庚华, 付兴科, 刘仁, 朱广彬, 欧阳斯达, 唐洪钊, 陈辉. 2021. 高分七号卫星双波束激光测高仪在轨几何检校与试验验证. *测绘学报*, 50(3): 384-395) [DOI: 10.11947/j.AGCS.2021.20200397]
- Terryr L, Calters K, Bartholomeus H, Bartolo R E, Brede B, D' Hont B, Disney M, Herold M, Lau A, Shenkin A, Whiteside T G, Wilkes P and Verbeeck H. 2022. Quantifying tropical forest structure through terrestrial and UAV laser scanning fusion in Australian rainforests. *Remote Sensing of Environment*, 271: 112912 [DOI: 10.1016/j.rse.2022.112912]
- Tian L, Wu X C, Tao Y, Li M Y, Qian C H, Liao L T and Fu W X. 2023. Review of remote sensing-based methods for forest aboveground biomass estimation: progress, challenges, and prospects. *Forests*, 14(6): 1086 [DOI: 10.3390/f14061086]
- Tompalski P, White J C, Coops N C and Wulder M A. 2019. Demonstrating the transferability of forest inventory attribute models derived using airborne laser scanning data. *Remote Sensing of Environment*, 227: 110-124 [DOI: 10.1016/j.rse.2019.04.006]
- Van Ewijk K, Tompalski P, Treitz P, Coops N C, Woods M and Pitt D. 2020. Transferability of ALS-derived forest resource inventory attributes between an eastern and western Canadian boreal forest mixedwood site. *Canadian Journal of Remote Sensing*, 46(2): 214-236 [DOI: 10.1080/07038992.2020.1769470]
- Van Passel J, de Keersmaecker W and Somers B. 2020. Monitoring woody cover dynamics in tropical dry forest ecosystems using sentinel-2 satellite imagery. *Remote Sensing*, 12(8): 1276 [DOI: 10.3390/rs12081276]
- Varvia P, Lähivaara T, Maltamo M, Packalen P, Tokola T and Seppänen A. 2017. Uncertainty quantification in ALS-based species-specific growing stock volume estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 55(3): 1671-1681 [DOI: 10.1109/TGRS.2016.2628960]
- Varvia P, Saarela S, Maltamo M, Packalen P, Gobakken T, Næsset E, Ståhl G and Korhonen L. 2024. Estimation of boreal forest bio-

- mass from ICESat-2 data using hierarchical hybrid inference. *Remote Sensing of Environment*, 311: 114249 [DOI: 10.1016/j.rse.2024.114249]
- Vastaranta M, Kankare V, Holopainen M, Yu X W, Hyypä J and Hyypä H. 2012. Combination of individual tree detection and area-based approach in imputation of forest variables using airborne laser data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67: 73-79 [DOI: 10.1016/j.isprsjprs.2011.10.006]
- Velikova M, Fernandez-Diaz J and Glennie C. 2024. ICESat-2 noise filtering using a point cloud neural network. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 11: 100053 [DOI: 10.1016/j.ophoto.2023.100053]
- Vorster A G, Evangelista P H, Stovall A E L and Ex S. 2020. Variability and uncertainty in forest biomass estimates from the tree to landscape scale: the role of allometric equations. *Carbon Balance and Management*, 15(1): 8 [DOI: 10.1186/s13021-020-00143-6]
- Walker W S, Gorelik S R, Cook-Patton S C, Baccini A, Farina M K, Solvik K K, Ellis P W, Sanderman J, Houghton R A, Leavitt S M, Schwalm C R and Griscom B W. 2022. The global potential for increased storage of carbon on land. *Proceedings of the National Academy of Sciences of the United States of America*, 119(23): e2111312119 [DOI: 10.1073/PNAS.2111312119]
- Wang C and Blei D M. 2018. A general method for robust Bayesian modeling. *Bayesian Analysis*, 13(4): 1163-1191 [DOI: 10.1214/17-BA1090]
- Wang D, Momo Takoudjou S and Casella E. 2020. LeWoS: a universal leaf-wood classification method to facilitate the 3D modelling of large tropical trees using terrestrial LiDAR. *Methods in Ecology and Evolution*, 11(3): 376-389 [DOI: 10.1111/2041-210X.13342]
- Wang Q, Pang Y, Chen D S, Liang X J and Lu J. 2021. Lidar biomass index: a novel solution for tree-level biomass estimation using 3D crown information. *Forest Ecology and Management*, 499: 119542 [DOI: 10.1016/j.foreco.2021.119542]
- Wang R Q, Li G Y, Lu Y G and Lu D S. 2024a. A comparative analysis of grid-based and object-based modeling approaches for poplar forest growing stock volume estimation in plain regions using airborne LiDAR data. *Geo-Spatial Information Science*, 27(5): 1441-1459 [DOI: 10.1080/10095020.2023.2169199]
- Wang R Q, Lu Y G, Lu D S and Li G Y. 2024b. Improving extraction of forest canopy height through reprocessing ICESat-2 ATLAS and GEDI data in sparsely forested plain regions. *GIScience and Remote Sensing*, 61(1): 2396807 [DOI: 10.1080/15481603.2024.2396807]
- Wang W W, Pang Y, Du L M, Zhang Z J and Liang X J. 2022. Individual tree segmentation for airborne LiDAR point cloud data using spectral clustering and supervoxel-based algorithm. *National Remote Sensing Bulletin*, 26(8): 1650-1661 (王伟伟, 庞勇, 杜黎明, 张钟军, 梁晓军. 2022. 超体素约简和谱聚类结合的机载LiDAR点云单木分割. 遥感学报, 26(8): 1650-1661) [DOI: 10.11834/jrs.20220189]
- Wang X W, Cheng X, Gong P, Huang H B, Li Z and Li X W. 2011. Earth science applications of ICESat/GLAS: a review. *International Journal of Remote Sensing*, 32(23): 8837-8864 [DOI: 10.1080/01431161.2010.547533]
- Wang Y S, Lehtomäki M, Liang X L, Pyörälä J, Kukko A, Jaakkola A, Liu J B, Feng Z Y, Chen R Z and Hyypä J. 2019b. Is field-measured tree height as reliable as believed – A comparison study of tree height estimates from field measurement, airborne laser scanning and terrestrial laser scanning in a boreal forest. *ISPRS Journal of Photogrammetry and Remote Sensing*, 147: 132-145 [DOI: 10.1016/j.isprsjprs.2018.11.008]
- Wang Y S, Pyörälä J, Liang X L, Lehtomäki M, Kukko A, Yu X W, Kaartinen H and Hyypä J. 2019a. In situ biomass estimation at tree and plot levels: what did data record and what did algorithms derive from terrestrial and aerial point clouds in boreal forest. *Remote Sensing of Environment*, 232: 111309 [DOI: 10.1016/j.rse.2019.111309]
- Werkowska W, Márquez A L, Real R and Acevedo P. 2017. A practical overview of transferability in species distribution modeling. *Environmental Reviews*, 25(1): 127-133 [DOI: 10.1139/er2016-0045]
- Williams J, Schonlieb C B, Swinfield T, Lee J, Cai X H, Qie L and Coomes D A. 2020. 3D Segmentation of trees through a flexible multiclass graph cut algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 58(2): 754-776 [DOI: 10.1109/tgrs.2019.2940146]
- Xi X H, Han T T, Wang C, Luo S Z, Xia S B and Pan F F. 2016. Forest above ground biomass inversion by fusing GLAS with optical remote sensing data. *ISPRS International Journal of Geo-Information*, 5(4): 45 [DOI: 10.3390/ijgi5040045]
- Xiao J F, Chevallier F, Gomez C, Guanter L, Hicke J A, Huete A R, Ichii K, Ni W J, Pang Y, Rahman A F, Sun G Q, Yuan W P, Zhang L and Zhang X Y. 2019. Remote sensing of the terrestrial carbon cycle: a review of advances over 50 years. *Remote Sensing of Environment*, 233: 111383 [DOI: 10.1016/j.rse.2019.111383]
- Xie D B, Huang H C, Feng L Y, Sharma R P, Chen Q, Liu Q W and Fu L Y. 2023. Aboveground biomass prediction of arid shrub-dominated community based on airborne Lidar through parametric and nonparametric methods. *Remote Sensing*, 15(13): 3344 [DOI: 10.3390/rs15133344]
- Xie D H, Wang X Y, Qi J B, Chen Y M, Mu X H, Zhang W M and Yan G J. 2018. Reconstruction of single tree with leaves based on terrestrial LiDAR point cloud data. *Remote Sensing*, 10(5): 686 [DOI: 10.3390/rs10050686]
- Xie X Y, Li A N and Jin H A. 2018. The simulation models of the forest carbon cycle on a large scale: a review. *Acta Ecologica Sinica*, 38(1): 41-54 (谢馨瑶, 李爱农, 靳华安. 2018. 大尺度森林碳循环过程模拟模型综述. 生态学报, 38(1): 41-54) [DOI: 10.5846/stxb201612122550]
- Xu D D, Wang H B, Xu W X, Luan Z Q and Xu X. 2021. LiDAR applications to estimate forest biomass at individual tree scale: opportunities, challenges and future perspectives. *Forests*, 12(5): 550 [DOI: 10.3390/f12050550]
- Xu Q, Man A, Fredrickson M, Hou Z Y, Pitkanen J, Wing B, Ramirez C, Li B and Greenberg J A. 2018. Quantification of uncertainty in

- aboveground biomass estimates derived from small-footprint airborne lidar. *Remote Sensing of Environment*, 216: 514-528 [DOI: 10.1016/j.rse.2018.07.022]
- Yan W Q, Guan H Y, Cao L, Yu Y T, Li C and Lu J Y. 2020. A self-adaptive mean shift tree-segmentation method using UAV LiDAR data. *Remote Sensing*, 12(3): 515 [DOI: 10.3390/rs12030515]
- Yang M X, Zhou X L, Peng C H, Li T, Chen K X, Liu Z L, Li P, Zhang C C, Tang J Y and Zou Z Y. 2023a. Developing allometric equations to estimate forest biomass for tree species categories based on phylogenetic relationships. *Forest Ecosystems*, 10: 100130 [DOI: 10.1016/j.fecs.2023.100130]
- Yang Q L, Niu C Y, Liu X Q, Feng Y H, Ma Q, Wang X J, Tang H and Guo Q H. 2023b. Mapping high-resolution forest aboveground biomass of China using multisource remote sensing data. *GIScience and Remote Sensing*, 60(1): 2203303 [DOI: 10.1080/15481603.2023.2203303]
- Yang Q Q, Jin C Y, Li T W, Yuan Q Q, Shen H F and Zhang L P. 2022. Research progress and challenges of data-driven quantitative remote sensing. *National Remote Sensing Bulletin*, 26(2): 268-285 (杨倩倩, 靳才溢, 李同文, 袁强强, 沈焕锋, 张良培. 2022. 数据驱动的定量遥感研究进展与挑战. *遥感学报*, 26(2): 268-285) [DOI: 10.11834/jrs.20211410]
- Zeide B. 1993. Analysis of growth equations. *Forest Science*, 39(3): 594-616 [DOI: 10.1093/forestscience/39.3.594]
- Zeng W S, Chen X Y and Yang X Y. 2023. Estimating changes of forest carbon storage in China for 70 years (1949-2018). *Scientific Reports*, 13(1): 16864 [DOI: 10.1038/S41598-023-44097-4]
- Zhang H Y, Feng Z K, Chen P P and Chen X F. 2019. Development of a tree growth difference equation and its application in forecasting the biomass carbon stocks of Chinese forests in 2050. *Forests*, 10(7): 582 [DOI: 10.3390/f10070582]
- Zhang W M, Shao J, Jin S N, Luo L, Ge J L, Peng X Y and Zhou G Q. 2021a. Automated marker-free registration of multisource forest point clouds using a coarse-to-global adjustment strategy. *Forests*, 12(3): 269 [DOI: 10.3390/f12030269]
- Zhang Y, Lu D S, Jiang X D, Li Y H and Li D Q. 2023. Forest structure simulation of eucalyptus plantation using remote-sensing-based forest age data and 3-PG model. *Remote Sensing*, 15(1): 183 [DOI: 10.3390/rs15010183]
- Zhang Y Z, Li W H and Liang S L. 2021b. New metrics and the combinations for estimating forest biomass from GLAS data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 7830-7839 [DOI: 10.1109/JSTARS.2021.3101285]
- Zhang Y Z, Liang S L and Sun G Q. 2014. Forest biomass mapping of northeastern China using GLAS and MODIS data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1): 140-152 [DOI: 10.1109/JSTARS.2013.2256883]
- Zhao P P, Lu D S, Wang G X, Liu L J, Li D Q, Zhu J R and Yu S Q. 2016b. Forest aboveground biomass estimation in Zhejiang Province using the integration of Landsat TM and ALOS PALSAR data. *International Journal of Applied Earth Observation and Geoinformation*, 53: 1-15 [DOI: 10.1016/j.jag.2016.08.007]
- Zhao P P, Lu D S, Wang G X, Wu C P, Huang Y J and Yu S Q. 2016a. Examining spectral reflectance saturation in Landsat imagery and corresponding solutions to improve forest aboveground biomass estimation. *Remote Sensing*, 8(6): 469 [DOI: 10.3390/rs8060469]
- Zhao R Q, Ni W J, Zhang Z Y, Dai H B, Yang C L, Li Z, Liang Y, Liu Q W, Pang Y, Li Z Y and Sun G Q. 2023a. Optimizing ground photons for canopy height extraction from ICESat-2 Data in mountainous dense forests. *Remote Sensing of Environment*, 299: 113851 [DOI: 10.1016/j.rse.2023.113851]
- Zhao Y T, Im J, Zhen Z and Zhao Y H. 2023b. Towards accurate individual tree parameters estimation in dense forest: optimized coarse-to-fine algorithms for registering UAV and terrestrial LiDAR data. *GIScience and Remote Sensing*, 60(1): 2197281 [DOI: 10.1080/15481603.2023.2197281]
- Zhen Z, Yang L, Ma Y, Wei Q B, Jin H I and Zhao Y H. 2022. Upscaling aboveground biomass of larch (*Larix olgensis* Henry) plantations from field to satellite measurements: a comparison of individual tree-based and area-based approaches. *GIScience and Remote Sensing*, 59(1): 722-743 [DOI: 10.1080/15481603.2022.2055381]
- Zheng Z J, Schmid B, Zeng Y, Schuman M C, Zhao D, Schaepman M E and Morsdorf F. 2023. Remotely sensed functional diversity and its association with productivity in a subtropical forest. *Remote Sensing of Environment*, 290: 113530 [DOI: 10.1016/J.RSE.2023.113530]
- Zhu X X, Nie S, Wang C, Xi X H, Lao J Y and Li D. 2022. Consistency analysis of forest height retrievals between GEDI and ICESat-2. *Remote Sensing of Environment*, 281: 113244 [DOI: 10.1016/j.rse.2022.113244]

Forest biomass estimation with LiDAR data

LU Dengsheng^{1,2}, JIANG Xiandie^{1,2,3}, LI Yunhe^{1,2}, WANG Ruqi^{1,2}, LI Guiying^{1,2}

1. Key Laboratory for Humid Subtropical Eco-Geographical Processes of the Ministry of Education, Fujian Normal University, Fuzhou 350117, China;

2. Institute of Geography, Fujian Normal University, Fuzhou 350117, China;

3. Fujian Normal University Geography Postdoctoral Station, Fuzhou 350117, China

Abstract: Forests as the largest carbon sink in the terrestrial ecosystems play important roles in mitigating climate change and maintaining ecological balance, thus, it is required to accurately map forest biomass distribution at timely manner. Remote sensing-based biomass estimation has obtained great attention in the past three decades, in particular, LiDAR due to its capability of capturing three-dimensional structure of forest stands has become an important data source for forest biomass estimation. LiDAR data can be acquired from different platforms such as close-ground, airborne and spaceborne, thus, they are used for biomass estimation at different scales such as individual trees, forest stands and landscapes. Many studies using LiDAR data for forest biomass estimation have been conducted, but no comprehensive review has been made so far. Therefore, this paper attempts to provide an overview of current situations of using LiDAR technologies for forest biomass estimation and discuss the challenges and potential solutions to improve biomass modeling performance at different scales. The research situations and existing problems on the biomass estimation at individual tree, plot, and landscape scales based on LiDAR data from different platforms (e.g., close-ground, airborne and spaceborne) were first described and the combination of LiDAR and other data sources such as optical, microwave radar, and auxiliary data for improvement of forest biomass estimation were then summarized and discussed; Different modeling methods such as regression, machine learning, deep learning, and hybrid methods were overviewed and the potential solutions to improve modeling accuracy through stratification were discussed; The potential factors causing biomass estimation uncertainty, the methods for examining and identifying uncertainty factors were described and then potential strategies to optimize the modeling procedure were discussed; The model transferability at time and space scales and the importance and challenge of constructing a universal forest biomass estimation model were then discussed. This paper highlighted the unique characteristics of LiDAR data from different platforms and indicated the necessity of incorporating LiDAR with other remotely sensed data for improving forest biomass estimation. This paper also indicated the importance of developing an optimized modeling procedure through examining modeling uncertainty and the values of developing a universal biomass estimation model through combination of physically based models and machine learning methods. This paper provided researchers a better understanding of the current situations of LiDAR technologies in forest biomass estimation research, and new insights for better employing relevant LiDAR data for improving forest biomass estimation at different scales.

Key words: forest biomass, close-ground LiDAR, airborne LiDAR, spaceborne LiDAR, multi-source data, modeling methods, uncertainty analysis, model transferability, model universality

Supported by National Natural Science Foundation of China (No. 32171787)