International Journal of Ecology 世界生态学, 2026, 15(4), 643-652
Published Online November 2026 in Hans. https://www.hanspub.org/journal/ije
https://doi.org/10.12677/ije.2026.154070

Hans汉斯

森林生物量估算研究进展

何　萍[1,2]，刘延坤[1,2*]，陈　瑶[1,3]，刘玉龙[1,3]，李云红[1,3]，戚福坤[1,2]

[1]黑龙江省生态研究所，黑龙江 哈尔滨
[2]黑龙江省森林生态与林业生态工程重点实验室，黑龙江 哈尔滨
[3]黑龙江牡丹江森林生态系统定位观测研究站，黑龙江 牡丹江

收稿日期：2026年9月18日；录用日期：2026年10月30日；发布日期：2026年11月10日

摘　要

森林生物量是评价森林生态系统生产力的重要指标，也是森林资源清查监测评价的重要参数。传统测量法和遥感估算法是开展森林生物量估算研究中广泛应用的方法。传统测量法精度高，可用于验证遥感估算的森林生物量，但费时费力，遥感估算法可获取大尺度的森林生物量，主要包括统计模型法、过程模型法和混合模型法3种。统计模型法是基于光学遥感或主动遥感数据结合实测数据建立数学模型，这类方法被广泛应用于区域森林生物量的估算研究中，过程模型法包括生理生态过程模型和光利用率模型，这类方法从机理层面上模拟森林植被生长中的光合作用、呼吸作用和养分循环等过程，具有较强的物理意义。混合模型结合了机理模型与数据驱动模型，兼顾机理模型的物理一致性以及深度学习模型的高数据驱动性能。本文综述了这3类方法获取森林生物量的研究进展以及存在的优缺点，最后提出未来的研究方向，为获取高精度的森林生物量研究提供理论参考。

关键词

森林生物量，传统测量方法，遥感反演

Research Progress on Estimating Forest Biomass

Ping He[1,2], Yankun Liu[1,2*], Yao Chen[1,3], Yulong Liu[1,3], Yunhong Li[1,3], Fukun Qi[1,2]

[1]Heilongjiang Institute of Ecology, Harbin Heilongjiang
[2]Key Laboratory of Forest Ecology and Forestry Ecological Engineering of Heilongjiang Province, Harbin Heilongjiang
[3]Mudanjiang Forest Ecosystem Research Station, Mudanjiang Heilongjiang

Received: September 18, 2026; accepted: October 30, 2026; published: November 10, 2026

*通讯作者。

文章引用: 何萍, 刘延坤, 陈瑶, 刘玉龙, 李云红, 戚福坤. 森林生物量估算研究进展[J]. 世界生态学, 2026, 15(4): 643-652. DOI: 10.12677/ije.2026.154070

Abstract

Forest biomass is a key indicator for evaluating the productivity of forest ecosystems and an important parameter for forest resource inventory, monitoring, and assessment. Traditional measurement methods and remote sensing estimation methods are widely used in forest biomass estimation research. Traditional measurement methods offer high accuracy and can be used to validate remote sensing estimates of forest biomass, but they are costly in terms of time and labor. Remote sensing estimation methods can provide forest biomass datasets at large scales. These mainly comprise three types: statistical modelling, process modelling and hybrid modelling. Statistical modeling methods establish mathematical models based on optical or active remote sensing data combined with field measurements. These methods are widely used in regional forest biomass estimation studies. Process modeling methods include physiological-ecological process models and light-use efficiency models. These methods simulate photosynthesis, respiration, and nutrient cycling processes during forest vegetation growth at the mechanistic level and possess strong physical significance. Hybrid models combine mechanistic models with data-driven models, balancing the physical consistency of mechanistic models with the high data-driven performance of deep learning models. This paper reviews the research progress, advantages, and disadvantages of these three approaches for estimating forest biomass. Lastly, we propose future research directions to provide a theoretical framework for studies aimed at obtaining high-precision forest biomass estimates.

Keywords

Forest Biomass, Traditional Measurement Methods, Remote Sensing Inversion

Copyright © 2026 by author(s) and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).
http://creativecommons.org/licenses/by/4.0/
Open Access

1. 引言

森林生态系统作为全球巨大的碳库，提供约 90%全球陆地植被生物量[1]-[4]，参与全球碳循环，在维护人类生存与发展、维持地球生态平衡方面具有不可替代的作用[5]。森林生物量在评价森林固碳能力方面发挥着重要的作用[6]，如何在大区域范围内准确监测森林生物量，对保障生态系统安全和维持全球碳平衡具有重要意义[7]，也是应对气候变化的迫切需求。传统测量法和遥感反演法是开展森林生物量估算研究中广泛应用的方法，本文总结了森林生物量的传统测量和遥感反演方法，并对不同方法获取森林生物量所存在的问题进行说明，提出以后的研究方向。

2. 传统测量森林生物量的方法

森林生物量的传统测量方法可分为直接法和间接法，直接法主要指收获法[8]，即将树木采伐后进行测量，这种方法测量的森林生物量精度最高，但破坏性很大，而且费时费力，很难在大区域应用。间接测量法主要通过建立异速生长方程间接估算森林生物量，可分为立木和林分两个尺度的生物量模型[9]-[11]，也可用林分尺度的蓄积量－生物量模型估算森林生物量[12] [13]。立木生物量模型又称相对林木生长关系模型，通过平均标准木或径级标准木方法，测定有限数量标准木的生物量，建立生物量与测树因子(胸径、树高等)之间的模型关系[14] [15]，进而对立木生物量进行估算。立木生物量的估算精度较高，

目前已有研究为北美、欧洲、尼日利亚等国外地区的多个树种建立了立木生物量模型[16]-[18]，国内也有研究采用该方法为秦皇岛、广西乃至全国的主要树种建立了立木生物量模型[19]-[21]。立木生物量模型通常根据单木组分(树枝、树叶、树干、树根、树皮)分别建立立木生物量估算模型，为了解决立木总生物量与各组分生物量的相容性问题，有研究学者建立了相容性模型以提高生物量估算精度[22] [23]。林分尺度的生物量可以通过单木尺度的相容性模型累加而获得[24]，也可以将林分尺度的测树因子(例如林分的平均树高和断面积)作为参数输入到立木生物量模型中[25]，从而获得林分尺度的生物量。基于林分生物量与林分蓄积量之间的线性关系，有研究建立了生物量－蓄积量转换模型[26]，因此可采用森林资源连续清查数据中的蓄积量获得林分尺度的森林生物量。

传统测量森林生物量的精度较高，可用于验证遥感反演的森林生物量，但只能用于获得特定区域内特定树种的生物量，难以获取大区域尺度的森林生物量。

3. 遥感估算森林生物量的方法

遥感传感器能够长期、全天候且大面积地对地同步观测，因此遥感估算法可有效提升大尺度森林生物量的获取效率[27]，森林生物量的遥感估算方法分为基于统计模型估算、基于过程模型和基于混合模型估算 3 种。

3.1. 基于统计模型遥感估算法

统计模型分为参数模型和非参数模型，参数模型主要是指传统的回归模型(如一元回归、多元线性回归模型等)，非参数模型主要是指机器学习模型，包括传统机器学习模型(如人工神经网络模型、随机森林等)和深度学习模型[28]。基于统计模型估算森林生物量的遥感数据源主要分为两类：被动遥感(光学遥感)和主动遥感(合成孔径雷达 SAR 和激光雷达)。

3.1.1. 被动遥感估算法

光学遥感的光谱信息丰富，能有效地反映植被生长情况[29] [30]，能够提取纹理信息、植被指数等大量有用信息，覆盖范围广，数据全，且成本低；纹理信息与林分结构之间的相关性较强，能够有效地降低空间异质性的影响[31]；植被指数可简单、有效地度量地表的植被状况，被广泛应用于评估植被生长状况、植被初级生产力和作物估产等方面[32]。

已有大量研究采用传统的回归模型对森林生物量进行估算，苟睿坤等人[33]运用 GF-2 影像提取了 13 种遥感因子(5 种植被指数和 8 种纹理信息)，建立了 5 种传统统计模型估算油松人工林的地上生物量，实现了较高精度的反演。蒋馥根等人[34]协同 GF-6 和 Sentinel-2 红边波段，采用逐步回归方法估算了旺业甸林场的落叶松和樟子松林的森林地上生物量，结果表明多元线性回归模型具有最优拟合效果。

近年来机器学习法在森林生物量估算研究中的应用逐渐增多，有研究基于异速生长方程与机器学习模型估算闽江河口秋茄红树林的森林地上生物量，发现随机森林模型的估算精度最高[35]。也有研究将多元线性回归模型、极端梯度提升算法、随机森林和 K 最近邻算法对广西高峰林场的森林地上生物量的估算精度进行对比分析，结果表明机器学习模型的估算森林生物量的精度更高，极端梯度提升算法在估算森林生物量的研究中具有较大的潜力[36]。

3.1.2. 主动遥感估算法

光学遥感数据估算森林生物量存在“光饱和”现象[37] [38]，而合成孔径雷达和激光雷达的波长较长，能够穿透茂密的植被冠层，并提取林分的垂直结构信息[39] [40]，见图 1，因此 LiDAR 和合成孔径雷达 SAR 数据被大量应用于森林生物量的估算研究中。然而，SAR 必须在特定频率的波段中工作[41]，SAR

传感器对森林生物量的敏感性取决于其波长，通常，较长的波长能穿透更深的森林冠层，更适用于森林生物量估算，然而，在轨卫星数量有限且此类数据成本高昂，使用长波长 SAR 数据存在挑战[42]。LiDAR 利用冠层高度模型(CHM, Canopy Height Model)获得研究区域的平均树高，通过构建估算模型对该区域的森林生物量估算[43]，大区域准确的 CHM 较难获取，且数据获取成本较高，数据处理复杂，覆盖区域有缺失，不利于开展区域的森林生物量估算[44]。目前，已有研究采用 SAR、LiDAR 协同中高空间分辨率的光学遥感数据估算森林生物量，结果表明联合数据源比单一数据源的估算精度高[45]-[47]。多源遥感数据估算森林生物量的示意图见图 2。



Figure 1. Schematic illustration of the “light saturation” phenomenon in optical remote sensing and the penetration advantages of LiDAR and SAR
图 1. 光学遥感的“光饱和”现象与 LiDAR/SAR 的穿透优势示意图

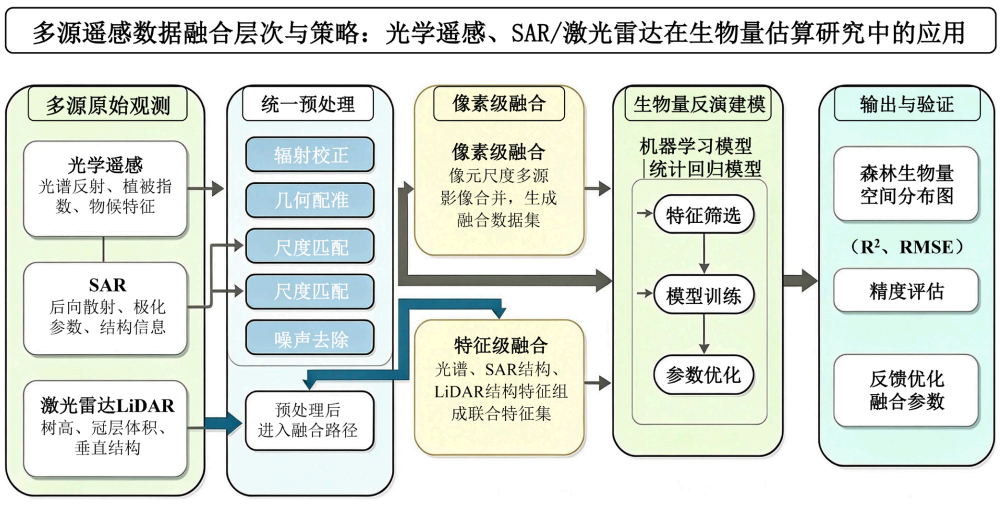


Figure 2. Schematic diagram illustrating the estimation of forest biomass using multi-source remote sensing data
图 2. 多源遥感数据估算森林生物量的示意图

不同遥感数据源估算森林生物量的优缺点见表 1。

Table 1. A Comparison of the advantages and disadvantages of estimating forest biomass using different remote sensing data sources
表 1. 不同遥感数据源估算森林生物量的优缺点对比

遥感数据源	优点	缺点
光学遥感	具有丰富的光谱信息，能够有效反映植被的生长情况，数据覆盖的时间和空间范围广，有大量可用的免费数据源。	难以穿透较深的植被冠层，对于茂密的植被冠层，存在“光饱和”现象，易受到云雨天气的影响。
激光雷达 LiDAR	能够穿透植被冠层，能够提取高精度的植被三维结构特征。	数据获取成本较高，数据处理复杂，覆盖区域有限，难以获取大范围数据。
合成孔径雷达 SAR	不易受云雨天气影响，可全天时全天候的监测，可以穿透植被冠层进而获得林分的垂直结构信息。	必须在特定频率的波段中工作，在轨卫星数量有限且此类数据成本高昂，数据处理复杂。

目前，全球生态系统动力学调查(Global Ecosystem Dynamics Investigation, GEDI)多波束激光雷达数据被广泛应用于估算森林生物量的研究中。已有研究在地中海地区基于 GEDI 数据估算了森林生物量，研究发现 GEDI 数据在高度分层复杂的森林中估算森林生物量具有不确定性，且出现低估现象[48]，因此有研究学者采用 GEDI 数据联合其他 LiDAR 数据估算森林生物量。孟鸽等人[49]联合 ICESat-2 和 GEDI 星载激光雷达数据，在古田山典型研究区采用随机森林法分森林类型建立了森林地上生物量外推估算模型，发现基于 ICESat-2 数据的估算精度明显高于 GEDI，联合 ICESat-2 和 GEDI 数据的精度最优。熊晓燕等人[50]联合 UAV-LiDAR 和 GEDI 数据采用随机森林法实现广西高峰林场的森林地上生物量估算，发现有效结合 UAV-LiDAR 和 GEDI 数据，能够克服实测样地数量有限和遥感数据空间不连续的问题，估算的研究区森林地上生物量的空间范围也更合理。

机器学习模型虽然能够有效处理变量间的非线性关系，但难以处理多维遥感图像中复杂的光谱关系，深度学习算法凭借其强大的特征提取能力，在目标识别、图像分类和大范围作物估算等方面展现优越，能够从高维数据中挖掘深层次特征，卷积神经网络(CNN)是常用的深度学习模型[51]，目前已有研究采用 CNN 模型估算森林生物量。Wang 等人[52]基于 GEDI 数据结合 MODIS VCF 的“未变化”训练样本选择流程，采用 4 种机器学习模型和深度学习模型(CNN 模型)对中国汉江流域 2015~2020 年的森林地上生物量，发现 CNN 模型的估算精度更高。有研究融合了 Sentinel-1/2 数据基于卷积神经网络(CNN)与 Transformer 架构相结合的方法，估算了蒙大拿州和爱达荷州的异质森林区域的森林地上生物量，发现 CNN-Transformer 集成模型表现优异，性能优于独立的 CNN 模型和视觉 Transformer 模型[53]。因此，深度学习模型在估算森林生物量的研究中具有很大的潜力。

3.2. 基于过程模型遥感估算法

基于过程模型遥感估算法是通过累加特定时间点之前的植被净初级生产力再减去损失，从而估算森林生物量，过程模型可分为生理生态过程模型和光利用率模型。生理生态过程模型主要是采用遥感手段获取的气象因子(如光照、温度、水分等)、植被生理生态参数(如植被类型、叶面积指数等)以及环境变量(如土壤和地形因子等)模拟植被冠层的光合作用和蒸腾作用[54] [55]，BIOME-BGC、TEM 和 BEPS 模型是常见生理生态过程模型。BIOME-BGC 模型机理性强，可以模拟不同植被群落的碳、氮、水循环过程[56]，已有研究采用参数本地化后的 BIOME-BGC 模型模拟了江西省修河流域森林的净初级生产力[57]。光利用率模型以植被吸收光合有效辐射比率(FPAR)和光能利用率等参数(可通过遥感数据获取的土地利

用类型、植被指数以及环境限制因子数据估算得到)为驱动因子，估算陆地生态系统的净初级生产力[58]，CASA 模型和 MOD17 模型是目前常用的光利用率模型，MODIS NPP 产品是由 MOD17 模型估算得到[59]。目前，已有研究采用改进的 CASA 模型对北京－张家口地区和京津冀地区的净初级生产力进行估算[60] [61]。基于统计模型与过程模型估算森林生物量的流程见图 3。

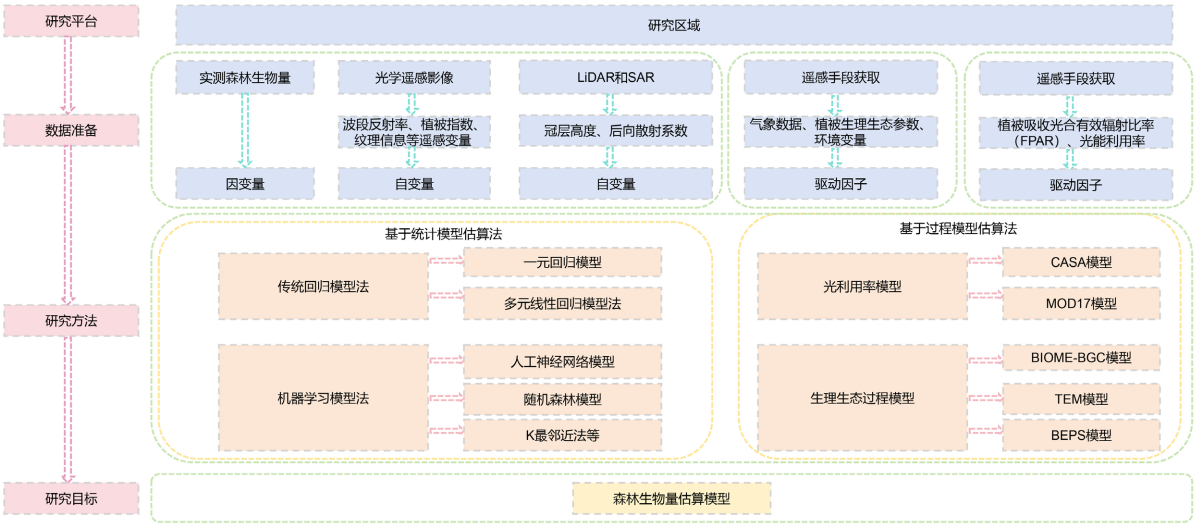


Figure 3. Flowchart for estimating forest biomass based on statistical and process models
图 3. 基于统计模型与过程模型估算森林生物量的流程图

不同模型遥感估算森林生物量的优劣见表 2。

Table 2. A comparison of the advantages and disadvantages of different models for estimating forest biomass using remote sensing
表 2. 不同模型遥感估算森林生物量的优缺点对比

遥感数据源	优点	缺点
传统回归模型	模型简单且易于实现，并且具有较强的可解释性和较高的计算效率。	当参数较多时，易受到变量间的多重共线性的影响，估算精度降低。
传统机器学习模型	处理变量间非线性与多重共线性的能力强，适用于变量较多且复杂的森林生物量估算。	需依赖大量的高质量训练样本，容易出现过度拟合的情况。
过程模型	从机理层面解释生态系统内部的碳循环作用，解释力强，空间适应性强。	参数众多，获取难度大，模型复杂，具有较高的不确定性。

3.3. 基于混合模型遥感估算法

生态系统过程模型(如 BIOME-BGC)的核心在于借助复杂的经验方程，完整描述大气、植被与土壤之间的物质交换及能量流动过程，鉴于环境持续变化且未来仍将持续演变，基于既往知识构建的模型可能不再适用，且模型的输入参数较多，准确测量这些参数较为困难；基于 SAR 数据的物理模型(如 WCM 模型)基于辐射传输理论，直接模拟微波与森林植被或地表之间的相互作用，包括体散射、地面散射及多次散射过程[62]，然而，物理模型的准确性仍受限于简化假设、参数敏感性、输入数据不确定性以及参数校准的复杂性。深度学习模型的准确性与泛化能力依赖于海量数据的“输入”，然而林业数据的采集需要

投入大量人力与物力资源，所获得的数据中可能存在噪声，此外，深度学习模型的训练过程不涉及任何物理机制，这可能在某些科学问题中引发不合理的模拟结果。因此，混合模型结合了机理模型与深度学习模型，能够兼具机理模型的物理一致性以及深度学习方法的高数据驱动性能[63]。Qin 等人[64]采用 3-PG 模型模拟林分生物量在叶片、茎干和根系间的分配情况，将所得到的估算值输入长短期记忆神经网络(LSTM)模型，建立森林生物量估算模型，研究表明混合模型具有更高的生物量模拟精度，并且对环境驱动因素的生物量响应更为真实。Zhao 等人[65]提出了一种可微分物理建模(DPM)方法，基于辐射传输理论的水云模型(WCM)作为物理框架，结合 GF-3 PolSAR 与 Radarsat-2 数据和 Landsat OLI 遥感数据，利用自动微分(AD)技术将 WCM 与深度全连接神经网络(DFCNN)无缝耦合，估算了云南省普洱市司马镇和内蒙古根河市的森林生物量，发现 DPM 模型在生态特征迥异的森林区域中均展现出稳定的性能。

4. 结语

目前主要可通过直接测量和遥感反演方法两种方法来获取森林生物量，不同方法之间存在差异，SAR、LiDAR 数据联合中高空间分辨率的光学遥感基于机器学习模型估算森林生物量的方法已展示了极大的潜力，较单一数据源估算森林生物量的精度高，改进的 BIOME-BGC 模型和 CASA 模型也被广泛应用于植被 NPP 的估算，但该过程模型的参数较多，获取成本高，未来的研究中应探索优化参数获取成本并提高估算精度，为获取高精度的森林生物量提供服务。混合模型(结合机理模型与数据驱动)在遥感估算森林生物量的研究中发挥了极大的优势，在多样化的森林生态系统中具有较好的稳健性与适应性，为利用遥感技术进行大规模森林生物量估算提供了可行路径。

基金项目

黑龙江省省属科研院所科研业务费项目(CZKYF2025-1-B035)。

参考文献

[1] 姜克隽, 贺晨旻, 庄幸. 我国能源活动 CO_2 排放在 2020-2022 年之间达到峰值情景和可行性研究[J]. 气候变化研究进展, 2016, 12(1): 167-171.

[2] Wai, P., Su, H. and Li, M. (2022) Estimating Aboveground Biomass of Two Different Forest Types in Myanmar from Sentinel-2 Data with Machine Learning and Geostatistical Algorithms. *Remote Sensing*, **14**, Article 2146. https://doi.org/10.3390/rs14092146

[3] Tian, L., Wu, X., Tao, Y., Li, M., Qian, C., Liao, L., *et al*. (2023) Review of Remote Sensing-Based Methods for Forest Aboveground Biomass Estimation: Progress, Challenges, and Prospects. *Forests*, **14**, Article 1086. https://doi.org/10.3390/f14061086

[4] Huang, H., Liu, C., Wang, X., Zhou, X. and Gong, P. (2019) Integration of Multi-Resource Remotely Sensed Data and Allometric Models for Forest Aboveground Biomass Estimation in China. *Remote Sensing of Environment*, **221**, 225-234. https://doi.org/10.1016/j.rse.2018.11.017

[5] Wang, X. and Jiao, H. (2020) Spatial Scaling of Forest Aboveground Biomass Using Multi-Source Remote Sensing Data. *IEEE Access*, **8**, 178870-178885. https://doi.org/10.1109/access.2020.3027361

[6] 刘沁茹, 孙睿. 森林生物量遥感降尺度研究[J]. 生态学报, 2019, 39(11): 3967-3977.

[7] 李云, 张王菲, 崔鎏波, 等. 参数优选支持的光学与 SAR 数据森林地上生物量反演研究[J]. 北京林业大学学报, 2020, 42(10): 11-19.

[8] 罗云建, 张小全, 王效科, 等. 森林生物量的估算方法及其研究进展[J]. 林业科学, 2009, 45(8): 129-134.

[9] Abich, A., Mucheye, T., Tebikew, M., Gebremariam, Y. and Alemu, A. (2018) Species-Specific Allometric Equations for Improving Aboveground Biomass Estimates of Dry Deciduous Woodland Ecosystems. *Journal of Forestry Research*, **30**, 1619-1632. https://doi.org/10.1007/s11676-018-0707-5

[10] Forrester, D.I., Tachauer, I.H.H., Annighoefer, P., Barbeito, I., Pretzsch, H., Ruiz-Peinado, R., *et al*. (2017) Generalized Biomass and Leaf Area Allometric Equations for European Tree Species Incorporating Stand Structure, Tree Age and

Climate. *Forest Ecology and Management*, **396**, 160-175. https://doi.org/10.1016/j.foreco.2017.04.011

[11] Sebrala, H., Abich, A., Negash, M., Asrat, Z. and Lojka, B. (2022) Tree Allometric Equations for Estimating Biomass and Volume of Ethiopian Forests and Establishing a Database: Review. *Trees, Forests and People*, **9**, Article ID: 100314. https://doi.org/10.1016/j.tfp.2022.100314

[12] 张春华, 居为民, 王登杰, 等. 2004-2013 年山东省森林碳储量及其碳汇经济价值[J]. 生态学报, 2018, 38(5): 1739-1749.

[13] 杨学云, 曾伟生, 陈新云. 北京市主要森林类型蓄积量生物量碳储量模型研建[J]. 林业资源管理, 2021(2): 124-130.

[14] 马正锐, 孟祥江, 师贺雄, 等. 重庆低山丘陵区典型针叶树种立木生物量模型构建研究[J]. 林草资源研究, 2026(1): 96-104.

[15] Garcia, R.A., Galvão, L.M.R., Chivale, X.S., Almeida, T.C., Pereira, F.R., Martins-Neto, R.P., *et al*. (2026) Comparing 30 Tree Biomass Models to Estimate Forest Biomass in the Amazon. *Forests*, **17**, Article 213. https://doi.org/10.3390/f17020213

[16] Ter-Mikaelian, M.T. and Korzukhin, M.D. (1997) Biomass Equations for Sixty-Five North American Tree Species. *Forest Ecology and Management*, **97**, 1-24. https://doi.org/10.1016/s0378-1127(97)00019-4

[17] Zianis, D. and Mencuccini, M. (2004) On Simplifying Allometric Analyses of Forest Biomass. *Forest Ecology and Management*, **187**, 311-332. https://doi.org/10.1016/j.foreco.2003.07.007

[18] Ajayi, S., Bassey, S.E. and Obi A.A. (2024) Carbon Sequestration and Linear Models for Individual Tree Biomass Estimation in Bebi Mixed Forest Plantation, Cross River State, Nigeria. *Asian Journal of Advanced Research and Reports*, **18**, 285-296. https://doi.org/10.9734/ajarr/2024/v18i12825

[19] 文嘉禄, 张春雪, 穆立蔷, 等. 秦皇岛市沿海地区刺槐立木生物量模型研究[J]. 西北林学院学报, 2025, 40(4): 147-156.

[20] 曾伟生. 基于木材密度的 34 个树种组一元立木生物量模型建立[J]. 林业资源管理, 2017(6): 41-46.

[21] 蔡会德, 农胜奇, 张伟, 等. 广西主要树种立木生物量模型的研建[J]. 林业资源管理, 2014(4): 58-61, 66.

[22] 张好, 董灵波, 卢军. 东北地区蒙古栎单木生物量及碳储量相容性模型研建[J]. 林业科学研究, 2025, 38(5): 105-116.

[23] 贺鹏, 陈振雄, 彭检贵. 湖南省主要树种单木相容性生物量模型系统研建[J]. 北京林业大学学报, 2025, 47(3): 61-72.

[24] 赵阳, 贾炜玮, 李凤日, 等. 大兴安岭地区不同林分类型的广义加性生物量模型构建[J]. 中南林业科技大学学报, 2025, 45(4): 52-64.

[25] 孙宇, 李凤日, 谢龙飞, 等. 基于林分及地形因子的落叶松人工林林分生物量模型构建[J]. 南京林业大学学报(自然科学版), 2023, 47(3): 129-136.

[26] 景春林, 周旺明, 许鹏, 等. 基于样地调查和连续清查的辽宁省森林生物量碳储量及潜力估算[J]. 生态学杂志, 2026, 45(7): 2195-2203.

[27] 蒋晋豫, 王海燕, 张馨之, 等. 基于 XGBoost 算法的森林生物量多源遥感反演[J]. 西北林学院学报, 2025, 40(2): 198-206+219.

[28] 邹文涛, 曾伟生. 森林生物量和碳储量估算研究进展[J]. 世界林业研究, 2025, 38(2): 32-38.

[29] Cui, Y., Sun, H., Wang, G., Li, C. and Xu, X. (2019) A Probability-Based Spectral Unmixing Analysis for Mapping Percentage Vegetation Cover of Arid and Semi-Arid Areas. *Remote Sensing*, **11**, Article 3038. https://doi.org/10.3390/rs11243038

[30] Hu, Y., Xu, X., Wu, F., Sun, Z., Xia, H., Meng, Q., *et al*. (2020) Estimating Forest Stock Volume in Hunan Province, China, by Integrating in Situ Plot Data, Sentinel-2 Images, and Linear and Machine Learning Regression Models. *Remote Sensing*, **12**, Article 186. https://doi.org/10.3390/rs12010186

[31] Vicharnakorn, P., Shrestha, R., Nagai, M., Salam, A. and Kiratiprayoon, S. (2014) Carbon Stock Assessment Using Remote Sensing and Forest Inventory Data in Savannakhet, Lao PDR. *Remote Sensing*, **6**, 5452-5479. https://doi.org/10.3390/rs6065452

[32] Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J., *et al*. (2004) Estimating Aboveground Biomass Using Landsat 7 ETM+ Data across a Managed Landscape in Northern Wisconsin, Usa. *Remote Sensing of Environment*, **93**, 402-411. https://doi.org/10.1016/j.rse.2004.08.008

[33] 苟睿坤, 陈佳琦, 段高辉, 等. 基于 GF-2 的油松人工林地上生物量反演[J]. 应用生态学报, 2019, 30(12): 4031-4040.

[34] 蒋馥根, 孙华, 李成杰, 等. 联合 GF-6 和 Sentinel-2 红边波段的森林地上生物量反演[J]. 生态学报, 2021, 41(20): 8222-8236.

[35] 赵伟滨, 纪北京, 孙圆, 等. 基于无人机与机器学习的闽江河口秋茄红树林分布与地上生物量协同监测研究[J]. 生态学报, 2026, 46(12): 6636-6655.

[36] 闫宇, 邓焯, 李斌, 等. 基于 Landsat 8 数据的人工林地上生物量估测模型研究[J]. 西北林学院学报, 2024, 39(5): 53-60+77.

[37] 郝晴, 黄昌. 森林地上生物量遥感估算研究综述[J]. 植物生态学报, 2023, 47(10): 1356-1374.

[38] 李紫荆, 刘彦枫, 冉娇, 等. 基于 Landsat 8 OLI 的云南元江流域森林生物量光学遥感估测及其饱和点分析[J]. 西南林业大学学报(自然科学), 2023, 43(1): 126-136.

[39] 李兰, 陈尔学, 李增元, 等. 森林地上生物量的多基线 InSAR 层析估测方法[J]. 林业科学, 2017, 53(11): 85-93.

[40] 邱赛, 邢艳秋, 徐卫华, 等. 星载大光斑 LiDAR 与 HJ-1A 高光谱数据联合估测区域森林地上生物量[J]. 生态学报, 2016, 36(22): 7401-7411.

[41] Gleason, C.J. and Im, J. (2011) A Review of Remote Sensing of Forest Biomass and Biofuel: Options for Small-Area Applications. *GIScience & Remote Sensing*, **48**, 141-170. https://doi.org/10.2747/1548-1603.48.2.141

[42] Ouchi, K. (2013) Recent Trend and Advance of Synthetic Aperture Radar with Selected Topics. *Remote Sensing*, **5**, 716-807. https://doi.org/10.3390/rs5020716

[43] 陈松, 孙华, 吴童, 等. 基于 Sentinel-2 与机载激光雷达数据的误差变量联立方程组森林蓄积量反演研究[J]. 中南林业科技大学学报, 2020, 40(12): 44-53.

[44] Lu, D., Chen, Q., Wang, G., Liu, L., Li, G. and Moran, E. (2014) A Survey of Remote Sensing-Based Aboveground Biomass Estimation Methods in Forest Ecosystems. *International Journal of Digital Earth*, **9**, 63-105. https://doi.org/10.1080/17538947.2014.990526

[45] 王璐, 姬永杰, 董文全, 等. 结合 Sentinel-2 和 GEDI 数据的森林地上生物量估测和空间格局分析[J]. 自然资源遥感, 2025, 37(5): 224-232.

[46] Borsah, A.A., Wong, M.S., Nazeer, M. and Shi, G. (2025) Machine Learning Models for Subtropical Forest Aboveground Biomass Mapping Using Combined SAR and Optical Satellite Imagery. *Remote Sensing Applications*: *Society and Environment*, **39**, Article ID: 101640. https://doi.org/10.1016/j.rsase.2025.101640

[47] Wang, Y., Hancock, S., Dong, W., Ji, Y., Zhao, H. and Wang, M. (2025) Analysis of the Application of Machine Learning Algorithms Based on Sentinel-1/2 and Landsat 8 OLI Data in Estimating Above-Ground Biomass of Subtropical Forests. *Forests*, **16**, Article 559. https://doi.org/10.3390/f16040559

[48] Dorado-Roda, I., Pascual, A., Godinho, S., Silva, C., Botequim, B., Rodríguez-Gonzálvez, P., *et al*. (2021) Assessing the Accuracy of GEDI Data for Canopy Height and Aboveground Biomass Estimates in Mediterranean Forests. *Remote Sensing*, **13**, Article 2279. https://doi.org/10.3390/rs13122279

[49] 孟鸽, 赵旦, 许聪, 等. 联合 ICESat-2 和 GEDI 星载激光雷达数据的森林地上生物量估算[J]. 遥感学报, 2024, 28(6): 1632-1647.

[50] 熊晓燕, 李彩霞, 柴国奇, 等. 联合 UAV-LiDAR 和 GEDI 数据的区域森林地上生物量估算[J]. 林业科学, 2025, 61(8): 142-153.

[51] 张邻晶, 马靓苗, 王亚茹, 等. 基于时空特征融合深度学习模型的半干旱森林地上生物量反演研究[J]. 生态学报, 2026, 46(17): 9277-9299.

[52] Wang, X., Zhang, Y., Atkinson, P.M. and Zhang, K. (2026) Estimating Spatiotemporally Continuous GEDI Aboveground Biomass Density during 2015-2020 from Multisource Data Using Machine Learning and Deep Learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **19**, 3839-3857. https://doi.org/10.1109/jstars.2025.3650357

[53] Irannejad, S. and Bagheri, H. (2026) Gaussian Mixture Integration of CNN and Transformer Models for Forest Biomass Estimation: A Multi-Sensor Fusion Approach with Uncertainty Quantification. *Smart Agricultural Technology*, **14**, Article ID: 102241. https://doi.org/10.1016/j.atech.2026.102241

[54] Chiesi, M., Chirici, G., Barbati, A., Salvati, R. and Maselli, F. (2011) Use of BIOME-BGG to Simulate Mediterranean Forest Carbon Stocks. *iForest—Biogeosciences and Forestry*, **4**, 121-127. https://doi.org/10.3832/ifor0561-004

[55] Liu, J., Chen, J.M., Cihlar, J., *et al*. (1997) A Process-Based Boreal Ecosystem Productivity Simulator Using Remote Sensing Inputs. *Remote Sensing of Environment*, **62**, 158-175. https://doi.org/10.1016/s0034-4257(97)00089-8

[56] White, M.A., Thornton, P.E., Running, S.W. and Nemani, R.R. (2000) Parameterization and Sensitivity Analysis of the BIOME-BGC Terrestrial Ecosystem Model: Net Primary Production Controls. *Earth Interactions*, **4**, 1-85.

https://doi.org/10.1175/1087-3562(2000)004<0003:pasaot>2.0.co;2

[57] 黄云, 胡方清, 郑博福, 等. 基于 Biome-BGC 模型的亚热带典型森林 NPP 动态模拟及气候响应[J]. 生态学杂志, 2025, 44(4): 1284-1296.

[58] Propastin, P.A., Kappas, M.W., Herrmann, S.M. and Tucker, C.J. (2011) Modified Light Use Efficiency Model for Assessment of Carbon Sequestration in Grasslands of Kazakhstan: Combining Ground Biomass Data and Remote-Sensing. *International Journal of Remote Sensing*, **33**, 1465-1487. https://doi.org/10.1080/01431161.2011.577105

[59] Zhang, D., Li, Y. and Gou, X. (2026) A Casa-Based, Modis-Constrained Framework for Consistent Annual NPP Simulation in Alpine Complex Environments: A Case Study of the Gannan Plateau. *Remote Sensing*, **18**, Article 2456. https://doi.org/10.3390/rs18152456

[60] Cui, K., Yang, F., Dong, Q., Wang, Z., Du, T. and Wang, Z. (2026) Spatial and Temporal Variation of Vegetation NPP in a Typical Area of China Based on the CASA Model. *Land*, **15**, Article 237. https://doi.org/10.3390/land15020237

[61] 花艺玮, 侯晒玥, 孟丹, 等. 基于 CASA 模型的京津冀植被 NPP 时空演变及城市化双重效应研究[J]. 中国环境科学, 2026, 46(8): 4473-4484.

[62] Liang, P., Pierce, L.E. and Moghaddam, M. (2005) Radiative Transfer Model for Microwave Bistatic Scattering from Forest Canopies. *IEEE Transactions on Geoscience and Remote Sensing*, **43**, 2470-2483. https://doi.org/10.1109/tgrs.2005.853926

[63] Perry, G.L.W., Seidl, R., Bellvé, A.M. and Rammer, W. (2022) An Outlook for Deep Learning in Ecosystem Science. *Ecosystems*, **25**, 1700-1718. https://doi.org/10.1007/s10021-022-00789-y

[64] Qin, J.H., Ma, M., Zhu, Y., Wu, B. and Su, X. (2023) 3PG-MT-LSTM: A Hybrid Model under Biomass Compatibility Constraints for the Prediction of Long-Term Forest Growth to Support Sustainable Management. *Forests*, **14**, Article 1482. https://doi.org/10.3390/f14071482

[65] Zhao, C., Shi, R., Ji, Y., Zhang, W., Zhang, W., He, X., *et al*. (2026) Differentiable Physical Modeling for Forest Above-Ground Biomass Retrieval by Unifying a Water Cloud Model and Deep Learning. *Remote Sensing*, **18**, Article 912. https://doi.org/10.3390/rs18060912