

融合有效极化度的全极化 SAR 数据森林地上生物量遥感反演研究

黄子加^{1,2}, 龙江平^{1,2}, 赵德良³, 林辉^{1,2}, 孙华^{1,2}, 张廷琛^{1,2}

1. 中南林业科技大学 林业遥感大数据与生态安全湖南省重点实验室, 长沙 410004;

2. 自然生态系统碳汇监测湖南省工程研究中心, 长沙 410004;

3. 山东省地质测绘院, 济南 250003

摘要: 全极化合成孔径雷达 SAR (Synthetic Aperture Radar) 数据能够有效刻画森林冠层的垂直结构特征, 在森林地上生物量 AGB (Above-Ground Biomass) 反演中具有重要的应用价值, 而合理的极化分解方法是提取关键极化特征并构建高精度定量反演模型的重要支撑。然而, 在复杂森林冠层条件下, 基于 Barakat 极化度的无模型分解方法在应对去极化效应、噪声干扰及观测几何变化时易产生偏差, 导致极化特征的稳定性与泛化能力受限。为此, 本研究在无模型分解框架中引入有效极化度 EDoP (Effective Degree of Polarization), 提出了一种融合 EDoP 的改进型无模型极化分解方法。以湖南省 3 个典型森林区域的 L 波段全极化 SAOCOM (SatéLite Argentino de Observaci6N Con Microondas) 影像为数据源, 分别采用模型分解、传统无模型分解及融合 EDoP 的无模型分解 3 种策略提取极化特征, 并结合前向特征选择与 4 种机器学习回归模型开展森林 AGB 定量反演。结果表明, 融合 EDoP 的方法显著改善了散射目标的功率分配: 体散射 VOL (volume scattering) 分量的能量占比由约 40% 降至 30%, 二次散射 DBL (Double-Bounce Scattering) 分量的能量占比提升约 20%, 有效抑制了由噪声和去极化引起的能量偏差, 增强了各散射分量与森林 AGB 之间的相关性, 尤其在冠层结构异质性较高的林分中表现更为突出。相较于传统无模型分解, 融合 EDoP 的无模型分解方法所提取的极化特征与 AGB 的相关性显著增强; 在森林 AGB 定量反演性能方面, 本文提出的方法使决定系数 (R^2) 提升 0.15—0.30、相对均方根误差 rRMSE (Relative Root Mean Square Error) 降低 4%—7%, 且生成的森林 AGB 空间分布图更加合理, 低估与高估现象均得到有效缓解, 延缓了森林 AGB 遥感反演的饱和效应。本研究进一步验证了融合 EDoP 的无模型分解方法在复杂林分中的稳健性与可迁移性, 证实其具备缓解森林 AGB 遥感反演饱和效应、提升复杂森林区域 AGB 反演精度的潜力, 对实现大范围森林生物量与碳储量的精细化监测具有重要的应用价值。

关键词: 森林 AGB, 有效极化度 (EDoP), 无模型极化分解, 机器学习, SAOCOM

中图分类号: TP79/P2

引用格式: 黄子加, 龙江平, 赵德良, 林辉, 孙华, 张廷琛. 2026. 融合有效极化度的全极化 SAR 数据森林地上生物量遥感反演研究. 遥感学报, 30(7): 2104–2120

Huang Z J, Long J P, Zhao D L, Lin H, Sun H and Zhang T C. 2026. Forest above-ground biomass inversion using full-polarimetric SAR data with integrated effective degree of polarization. National Remote Sensing Bulletin, 30(7): 2104–2120 [DOI: 10.11834/jrs.20265452]

1 引言

合成孔径雷达 SAR (Synthetic Aperture Radar) 具备全天时、全天候的观测能力, 能够在多云、多雨等复杂气象条件下稳定获取森林观测信息, 已成为森林地上生物量 AGB (Above-Ground Biomass)

遥感反演的重要数据来源 (Santoro 和 Cartus, 2018; 李增元 等, 2020)。相比单极化或双极化 SAR 数据, 全极化 SAR 数据对森林冠层结构特征具有更高的敏感性, 尤其在高生物量森林中响应能力更强, 这有助于缓解森林生物量遥感反演的饱和效应, 并提升森林 AGB 的估算精度 (Cartus 和 Santoro,

收稿日期: 2025-11-11; 预印本: 2026-05-13

基金项目: 国家自然科学基金 (编号: 32171784, 42030112)

第一作者简介: 黄子加, 研究方向为植被定量遥感。E-mail: zijiahuang310@gmail.com

通信作者简介: 龙江平, 研究方向为林业遥感、智慧林业和微波遥感。E-mail: longjiangping@csuft.edu.cn

2019; Zolkos 等, 2013)。近年来, C波段与L波段的全极化 SAR 数据已多次应用于针叶林及结构复杂的次生林森林 AGB 反演中, 并展现出显著的应用潜力 (Zeng 等, 2022; Zhang 等, 2022)。然而, 全极化 SAR 数据森林 AGB 的定量反演精度仍高度依赖于所提取的极化特征与林分结构参数之间的敏感程度。因此, 如何有效提取与林分参数高度敏感的极化特征, 仍是当前研究面临的关键挑战。

基于全极化 SAR 数据提取的极化特征主要包括不同极化的后向散射系数、各种极化分解方法提取的极化分解特征及其纹理特征, 其中极化分解特征是森林 AGB 遥感定量反演的关键特征。目前, 极化分解特征主要是以协方差矩阵 ($C3$) 或相干矩阵 ($T3$) 为基础, 利用不同极化分解方法提取的具有明确物理涵义的散射分量, 反映了不同地物的散射机理与结构特征 (Han 等, 2022)。传统的 Freeman-Durden 三分量和 Yamaguchi 四分量等基于模型的极化分解方法被广泛用于森林参数估测, 研究结果发现极化分解特征能够有效定量表征植被覆盖度及其生物量信息 (Cloude 和 Pottier, 1996; Freeman 和 Durden, 1998; Yamaguchi 等, 2005)。此外, 已有研究表明, 基于模型的极化分解方法提取的体散射 VOL (volume scattering) 分量与森林 AGB 具有较高的敏感性, 结合随机森林等特征筛选算法可有效改善 AGB 遥感估测结果, 表明极化分解参数在森林 AGB 估测中具有重要的应用价值 (Yu 等, 2024; Kumar 等, 2019)。然而, 传统基于模型的极化分解方法过多依赖多重分支条件来计算散射功率分量, 在面对复杂地表地物时易产生负功率、散射类型混淆等现象 (Li 等, 2023)。特别是复杂林分结构或异质性显著的森林, 传统基于模型的极化分解结果容易受到噪声、地形及去极化效应的干扰, 导致极化分解精度下降和功率分配失衡 (Nie 等, 2024)。尽管基于模型的极化分解方法为森林 AGB 遥感定量反演奠定了理论基础, 但其对结构复杂性和非理想散射目标的适应性不足, 已成为制约林分结构参数反演精度与稳定性的重要瓶颈。

为克服基于模型的极化分解方法在结构复杂林分中的适用性限制, 无模型极化分解方法逐渐成为极化 SAR 数据应用于森林 AGB 估测的重要发展方向 (Karachristos 等, 2024)。该方法不依赖假定几何散射模型, 而是基于目标的极化度、相干

性及散射不对称性等特征参数表征散射特征, 且在异质林分和不规则冠层结构条件下表现出更高的稳健性与泛化能力 (Wang 和 Zhao, 2010; Wang 等, 2019)。除无模型极化分解方法外, 基于统计特征的极化分解方法同样在极化 SAR 数据分析中得到广泛应用, 其中以 Cloude 和 Pottier (1997) 及 Zhang 等 (2024) 提出的极化熵 (H)、各向异性 (A) 与散射类型角 (α) 分解为代表的统计特征分解, 通过对相干矩阵/协方差矩阵进行特征值与特征向量分析, 提取 H 、 A 与 α 等参数, 用于刻画散射过程的随机性及主导散射机制, 相关特征已被用于植被/森林结构分析与生物量反演等研究。与之相比, 本文采用并改进的无模型极化分解方法虽同样建立在极化统计量基础上, 但其核心目标是在不依赖几何散射模型假设的前提下, 将总功率 (Span) 分解为具有明确物理含义的散射功率分量并满足功率守恒, 从而更便于开展散射能量分配及其与森林 AGB 之间关系的定量分析。已有研究表明, 无模型分解方法在森林结构复杂性较高的区域中具有更强的适应性与物理可解释性。例如, 基于 L 波段全极化 PALSAR-2 数据和无模型极化分解方法获取的极化特征, 与森林 AGB 的相关性明显优于传统方法, 且估测森林 AGB 的相对均方根误差 rRMSE (relative Root Mean Square Error) 降低至 22.95% (Peng 等, 2025)。极化度是无模型极化分解方法中表征目标散射纯度与有序性的关键参数, 其变化能够反映散射过程的结构复杂度与随机性特征 (Cloude 等, 1996)。然而, 无模型极化分解方法的核心参数——Barakat 极化度的计算依赖相干矩阵 T 的行列式及其迹, 该参数在高噪声条件下的鲁棒性较差, 可能导致极化度估计出现偏差与不稳定, 进而导致体散射能量估计的波动, 最终影响森林 AGB 反演模型的泛化性能 (Nunziata 等, 2013; Dey 等, 2021b)。

有效极化度 EDoP (Effective Degree of Polarization) 在表征极化状态特性方面具有显著优势 (Vahimaa 和 Tervo, 2004; Bhattacharya 等, 2015)。相较于依赖全局统计的 Barakat 极化度, EDoP 通过分别计算水平极化度 m_H 和垂直极化度 m_V , 能够更精细地捕捉局部极化特征, 尤其在部分极化向完全极化过渡的阶段表现突出, 因此在描述局部极化特性时更具优势 (Ratha 等, 2017; Muhuri 等, 2016)。此外, EDoP 通过区分不同极化方向的分量, 提升

了对噪声的鲁棒性；在数据复杂或信噪比较低的情况下仍能保持较高的稳定性，可有效抑制噪声和异常值对极化度估计的干扰（Bhattacharya 和 Surendar, 2016）。因此，EDoP 综合了水平与垂直方向的极化信息，不仅提高了极化度估计的分辨率与精度，还能在森林和城市等复杂场景下更准确地区分不同的极化状态，增强对部分极化波形的识别能力，从而更好地适应多样化的极化模式。

针对无模型极化分解的核心参数 Barakat 极化度导致极化度估计不稳定性且存在偏差的问题，本文在无模型极化分解框架中引入 EDoP，提出了一种改进的无模型极化分解方法，旨在提高极化特征描述复杂森林场景中体散射信息的准确性，并增强极化分解特征对散射纯度与去极化特征的稳健表征能力。本文选择湖南省典型的针叶林和针阔混交林等作为研究对象，以 L 波段全极化 SAOCOM 影像为研究数据，将 EDoP 融入无模型极化分解框架，构建了改进的无模型三分量和四分量极化分解方法，并结合前向特征筛选框架和机器学习模型构建森林 AGB 估测模型，定量评价改进方法在复杂森林环境中对森林 AGB 定量估测的稳健性与适用性。

2 研究区与数据

2.1 研究区

本研究选取森林类型和林分结构差异明显的湖南省株洲市攸县的黄丰桥林场、永州市新田县以及长株潭绿心区等 3 个研究区，涵盖了湖南省典型的针叶林和针阔混交林等森林类型。其中，黄丰桥林场位于株洲市攸县中东部（26°59'N—27°21'N，113°45'E—114°13'E），地貌以中低山丘陵为主，海拔 115—1270 m，属中亚热带季风湿润气候，森林以针叶树种占优势，主要包括杉木（*Cunninghamia lanceolata*）、马尾松（*Pinus massoniana*）和湿地松（*Pinus elliottii*），局部伴有阔叶树种，如樟树（*Cinnamomum camphora*）。新田县位于永州市最南部（25°58'N—26°23'N，112°00'E—112°31'E），地形呈低山—丘陵—台地过渡，海拔 100—1707 m，森林类型以针阔混交林为主，主要包括马尾松、杉木及常绿阔叶树。长株潭绿心区位于长沙、株洲、湘潭三市交汇地带，面积约 528 km²，地貌为低山丘陵，森林类型以针阔混交林为主，针叶林与阔叶林镶嵌分布，地形起伏多样、林分类型复杂、冠

层结构层次丰富，是典型的高林分异质性区域，主要树种包括马尾松、杉木、苦槠（*Castanopsis sclerophylla*）、樟科与壳斗科阔叶树及毛竹（*Phyllostachys edulis*）。

2.2 地面调查数据及其预处理

为获取与遥感数据同步的森林 AGB 样本，本研究在 3 个研究区布设了地面样地，并开展地面调查，其中黄丰桥林场（2022 年 7 月—8 月）和新田县（2024 年 5 月—8 月）样地布设面积为 20 m×20 m，长株潭绿心区（2022 年 4 月—8 月）样地布设面积为 25.82 m×25.82 m。在每个样地调查中，采集了树种、胸径 DBH（Diameter at Breast Height）、树高（*H*）、冠幅和郁闭度等单木和林分结构参数。单木 AGB 依据《温室气体自愿减排项目方法学 造林碳汇（CCER-14-001-V01）》中主要乔木林树种的单木生物量与胸径或树高的相关方程进行计算（表 1），样地尺度生物量通过汇总样地内所有单木 AGB 计算得到，并换算为单位面积生物量（单位：t/hm²）。各研究区森林 AGB 统计结果见表 2。

考虑到不同森林类型在林分结构和极化散射特性上存在明显差异，为验证融合有效极化度的无模型分解方法在不同林分类型和复杂林分中的稳健性与可迁移性，本文依据《全国生态状况调查评估技术规范—生态系统遥感解译与野外核查》（HJ 1166—2021）中森林类型划分标准，将研究区样本的森林划分为针叶林和针阔混交林两类（表 3）。

2.3 遥感数据及其预处理

为了构建森林 AGB 遥感定量反演模型，本研究在 3 个研究区分别获取了 3 景 L 波段全极化 SAOCOM 数据（表 3）。全极化 SAR 影像成像过程中容易受到环境、系统噪声及地形效应等多重因素的干扰，导致影像中常出现散射信息异常、噪声增强及几何畸变等问题。为确保各个极化散射特征的真实性与稳定性，本研究对 L 波段全极化 SAOCOM 数据进行了辐射校正、极化滤波、地形校正和地理编码等预处理。首先，对影像进行辐射定标，将雷达回波振幅信息转换为具有物理意义的后向散射系数，以增强其定量分析能力。随后，采用多视处理与 5×5 窗口的增强型 Lee 滤波，削弱相干斑噪声的影响，改善纹理与散射特征的可解释性。最后，针对复杂地形引起的压缩、重叠和阴影畸变，引入地形辐射校正以补偿能量分布的空间不均，并采

用空间分辨率为 12.5 m 的 ASTER GDEM（Advanced Spaceborne Thermal Emission and Reflection radiometer Global Digital Elevation Model）数字高程模型 DEM（Digital Elevation Model）数据对图像进行地理编码。




图 1 研究区及其地面样本的分布
Fig. 1 The study area and ground measured samples

表 1 森林 AGB 计算公式
Table 1 Formula for calculating forest aboveground biomass

计算公式	森林类型 或树种	模型参数		
		<i>a</i>	<i>b</i>	<i>c</i>
$M = a \cdot \text{DBH}^b \cdot H^c$	杉木	0.06539	2.01735	0.49430
	马尾松	0.06662	2.09317	0.49760
	湿地松	0.04744	2.10359	0.63110
$Y = a \cdot (\text{DBH}^2 \cdot H)^b \cdot 10^{-3}$	樟树	5.76800	1.18460	
	阔叶树	119.16320	0.85420	

注：M 和 Y 为单株生物量，单位为 kg；DBH 为胸径，单位为 cm；H 为树高，单位为 m。a、b、c 为不同树种生物量计算方程中的模型参数，其中 a 为尺度系数，b 和 c 为幂指数系数；当公式中不包含 c 时，该参数不适用。

需要说明的是，本文所用地面调查数据与 SAOCOM 全极化 SAR 影像在获取时间上存在一定差异。鉴于研究区以中龄林和成熟林为主，林分结构稳定，森林 AGB 在短时间内增长量较小，因此影像获取时间差异对森林 AGB 空间分布格局及不同极化分解方法的对比结果影响有限。

3 研究方法

3.1 总体技术路线

为了定量评价 EDoP 的无模型分解方法对复杂

森林场景的描述能力，并探索其对森林 AGB 定量反演的潜力，本研究以湖南省 3 个典型森林区域的 L 波段全极化 SAOCOM 影像为数据源，分别采用基于模型分解、传统无模型分解和改进无模型分解 3 种分解策略提取极化特征。进而结合地面样地调查数据，采用前向特征选择与 4 种机器学习回归模型进行森林 AGB 反演，定量评价改进的无模型极化分解方法在复杂森林环境中对森林 AGB 定量估测的稳健性与适用性（图 2）。

3.2 基于模型分解方法

传统基于模型极化分解方法（如 Freeman–Durden 分解、Yamaguchi 分解等）通过对协方差矩阵进行物理建模，将极化散射特征分解为表面散射、二次散射与体散射等 3 种主要散射机制（Freeman 和 Durden，1998；Yamaguchi 等，2005）。这类方法在物理意义上具有较强的可解释性，可有效分析地物的散射组成，对森林、农田等典型地物具有良好的适用性（Hu 等，2023）。然而，基于模型的分解方法通常依赖于对目标散射机理的先验假设，当实际地物结构复杂或散射机制混合时，模型假设与真实情况可能不符，从而导致分解结果偏差，影响后续参数的反演精度。

表2 研究区森林AGB统计结果

Table 2 Summary statistics of forest aboveground biomass in the study area

研究区	时间	样本数量	均值/(t·hm ⁻²)	范围/(t·hm ⁻²)	标准差/(t·hm ⁻²)	变异系数/%
黄丰桥林场	2022年7月—8月	64	108.95	45.54—253.13	35.18	32.29
新田县	2024年5月—8月	91	71.35	12.67—175.41	37.29	52.26
长株潭绿心区	2022年4月—8月	64	110.55	12.01—233.74	45.41	41.08

表3 森林类型划分

Table 3 Classification of forest type

森林类型	说明
针叶林	郁闭度≥0.2且针叶树种的蓄积量占80%以上的林地
针阔混交林	针叶或阔叶树种的蓄积量占林分蓄积量20%—80%的林地

注：“结构异质性”主要用于描述林分在垂直结构和空间分布上的复杂程度,不作为独立的分类标准。

表4 研究区全极化SAOCOM数据的详细信息

Table 4 Detailed information of acquired quad-polarimetric SAOCOM data

研究区	传感器	波段	获取时间	空间分辨率/m	极化方式
黄丰桥林场	SAOCOM-1B	L波段	2022-08-26	10	全极化
	SAOCOM-1A	L波段	2022-09-03	10	全极化
	SAOCOM-1B	L波段	2022-09-11	10	全极化
新田县	SAOCOM-1B	L波段	2024-10-13	10	全极化
	SAOCOM-1A	L波段	2024-10-21	10	全极化
	SAOCOM-1B	L波段	2024-10-29	10	全极化
长株潭绿心区	SAOCOM-1B	L波段	2022-09-19/10-13	10	全极化
	SAOCOM-1B	L波段	2022-09-27/10-21	10	全极化
	SAOCOM-1B	L波段	2022-10-05/10-29	10	全极化




图2 技术路线

Fig. 2 Technical route

3.3 无模型分解方法

为了克服传统基于模型分解方法在复杂地物或异质性显著区域中适用性受限的问题,近年来无模型极化分解方法逐渐受到关注。该方法通

过对矩阵进行统计特征分解,不依赖具体的几何模型假设。在该框架下,极化度被视为刻画散射过程有序程度与随机性的重要物理量,其数值反映了散射机制由确定性向随机性过渡的程度。无

模型极化分解正是通过极化度与散射类型参数对总功率 (Span) 进行调制和划分, 将散射能量分配至具有明确物理意义的散射分量, 从而在复杂森林环境中表现出更好的适应性和灵活性 (Wang 等, 2019)。无模型三分量极化分解基于三维 Barakat 极化度 m_{FP} 与散射类型角 θ_{FP} 对目标总功率 (Span) 进行分解, 其中 m_{FP} 由 3×3 相干矩阵 $\mathbf{T}$ 定义为

$$m_{\text{FP}} = \sqrt{1 - \frac{27|\mathbf{T}|}{(\mathbf{T}_r(\mathbf{T}))^2}} \in [0, 1] \quad (1)$$

式中, $\mathbf{T}$ 表示矩阵的行列式, $\mathbf{T}_r(\mathbf{T})$ 表示矩阵的迹, 即其对角元素之和。

θ_{FP} 由矩阵对角元素及 m_{FP} 计算得到, 其取值范

$$\mathbf{K} = \begin{bmatrix} \frac{\mathbf{T}_{11} + \mathbf{T}_{22} + \mathbf{T}_{33}}{2} & \Re(\mathbf{T}_{12}) & \Re(\mathbf{T}_{13}) & \Im(\mathbf{T}_{23}) \\ \Re(\mathbf{T}_{12}) & \frac{\mathbf{T}_{11} + \mathbf{T}_{22} - \mathbf{T}_{33}}{2} & \Re(\mathbf{T}_{23}) & \Im(\mathbf{T}_{13}) \\ \Re(\mathbf{T}_{13}) & \Re(\mathbf{T}_{23}) & \frac{\mathbf{T}_{11} - \mathbf{T}_{22} + \mathbf{T}_{33}}{2} & -\Im(\mathbf{T}_{12}) \\ \Im(\mathbf{T}_{23}) & \Im(\mathbf{T}_{13}) & -\Im(\mathbf{T}_{12}) & \frac{-\mathbf{T}_{11} + \mathbf{T}_{22} + \mathbf{T}_{33}}{2} \end{bmatrix} \quad (3)$$

$$\theta_{\text{FP}} = \tan^{-1} \left(\frac{4m_{\text{FP}}\mathbf{K}_{11}\mathbf{K}_{44}}{\mathbf{K}_{44}^2 - (1 + 4m_{\text{FP}}^2)\mathbf{K}_{11}^2} \right) \in [-45^\circ, 45^\circ] \quad (4)$$

$$\tau_{\text{FP}} = \tan^{-1} \left(\frac{|\mathbf{K}_{14}|}{\mathbf{K}_{11}} \right) \in [0^\circ, 45^\circ] \quad (5)$$

式中, $\Re$ 和 $\Im$ 分别表示复数的实部和虚部, $\mathbf{K}_{11} = (\mathbf{T}_{11} + \mathbf{T}_{22} + \mathbf{T}_{33})/2$ 和 $\mathbf{K}_{44} = (-\mathbf{T}_{11} + \mathbf{T}_{22} + \mathbf{T}_{33})/2$ 。在此基础上, 总功率可分解为 4 个散射分量: 二次散射功率、表面散射功率、体散射功率和螺旋散射功率 ($P_e(\text{HLX})$)。该方法不仅保留了三分量分解对主要散射机理的区分能力, 还通过引入不对称性参数有效刻画了螺旋散射成分, 从而提升了其在复杂森林环境中的分解适用性。

3.4 融合有效极化度的无模型分解方法

3.4.1 有效极化度

无模型极化分解的核心参数 Barakat 极化度在计算时依赖相干矩阵 $\mathbf{T}$ 的行列式及其迹。在森林场景的极化 SAR 数据中, 当后向散射信号偏弱、有效信噪比下降时, 相干矩阵的局部估计更易受到噪声项与残余相干斑影响, 这一现象在林缘与裸地过渡带等混合像元区域、冠层稀疏引起的低散射强度区域, 以及复杂地形造成的阴影与几何衰减区域尤为显著。在上述条件下, 矩阵元素的扰动更

围为 $[-45^\circ, 45^\circ]$, 其公式为

$$\theta_{\text{FP}} = \tan^{-1} \left(\frac{m_{\text{FP}}\text{Span}(\mathbf{T}_{11} - \mathbf{T}_{22} - \mathbf{T}_{33})}{\mathbf{T}_{11}(\mathbf{T}_{22} + \mathbf{T}_{33}) + m_{\text{FP}}^2\text{Span}^2} \right) \quad (2)$$

基于此, 可将总功率 (Span) 划分为二次散射功率 [$P_d(\text{DBL})$]、表面散射功率 [$P_s(\text{ODD})$] 和体散射功率 [$P_v(\text{VOL})$] 3 类成分。

无模型四分量极化分解通过将相干矩阵 $\mathbf{T}$ 转换为 4×4 的 Kennaugh 矩阵 $\mathbf{K}$, 并结合旋转不变散射参数和目标不对称性特征, 实现了对三分量形式的扩展 (Dey 等, 2021a)。三维极化度 m_{FP} 仍由相干矩阵定义, 散射类型角 θ_{FP} 与矩阵 $\mathbf{K}$ 元素有关。同时, 螺旋散射角 τ_{FP} 用于刻画目标散射的不对称性, 具体的公式为

容易在行列式及其迹的运算中累积并被放大, 使 Barakat 极化度估计出现明显波动或偏差, 从而降低分解中功率分配的稳定性与可重复性。基于这一考虑, 本文在保持无模型极化分解原有物理框架不变的前提下, 引入了 EDoP 替代 Barakat 极化度作为极化度量指标。EDoP 同样用于表征散射过程的极化特性, 但与三维 Barakat 极化度的定义方式不同。Barakat 极化度基于相干矩阵的整体统计量构造, 侧重从全局角度表征去极化作用与散射随机性, 而 EDoP 遵循缪勒—斯托克斯 (Mueller-Stokes) 描述链路, 在给定入射极化态条件下, 分别估计水平线偏振入射与垂直线偏振入射对应的接收波极化度 m_{H} 与 m_{V} , 并据此计算有效极化度 (Manickam 等, 2017)。本文选择水平 (H) 与垂直 (V) 两种线偏振入射极化态的组合形式, 主要基于观测配置与分解框架的输入约束: 极化 SAR 数据的观测与相干矩阵构建均以 H/V 正交线偏振为基础。因此, 本文所采用的 EDoP 可理解为目标在 H 与 V 两种典型线偏振入射条件下综合去极化响应的定量表征。若进一步引入多种代表性入射极化态并对其极化度进行平均, 需要预先规定入射极化态集合及其权重设定, 使结果对入射极化态选取与权重设定产生依赖, 并增加不确定性来源。

三维 Barakat 极化度在物理意义上能够更全面反映目标对入射波去极化作用所对应的散射随机性，但在无模型分解中，极化度直接参与功率调制与分配，其估计波动会更直接地传递至各散射分量的功率中。本文引入 EDoP 旨在不改变散射分量定义方式与功率守恒约束的条件下，选取与观测入射配置一致且在像元尺度更具稳定性的极化度输入，从而提高分解结果的稳定性与可重复性。

EDoP 的计算与相干矩阵 T_3 关，首先对相干矩阵 T_3 施加旋转矩阵 $R(\theta)$ ，即

$$[R(\theta)] = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(2\theta) & \sin(2\theta) \\ 0 & -\sin(2\theta) & \cos(2\theta) \end{bmatrix} \quad (6)$$

式中， θ 为实旋转角，用于减弱目标取向角对相干矩阵的影响，其取值通过最小化旋转后相干矩阵中的 $T_{33}(\theta)$ 分量确定，随后，为进一步优化相干矩阵并计算有效极化度，引入第一个复数酉变换矩阵 $[R(\varnothing_1)]$ ，即

$$[R(\varnothing_1)] = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(2\varnothing_1) & j\sin(2\varnothing_1) \\ 0 & j\sin(2\varnothing_1) & \cos(2\varnothing_1) \end{bmatrix} \quad (7)$$

式中， j 为虚数单位，该矩阵作用于旋转后的相干矩阵 $[T(\theta)]$ 矩阵，即

$$\langle [T(\varnothing_1)] \rangle = [R(\varnothing_1)] \langle [T(\theta)] \rangle [R(\varnothing_1)]^{-1} \quad (8)$$

在本文的改进方案中，进一步引入第二个复数单位变换矩阵 $[R(\varnothing_2)]$ ：

$$[R(\varnothing_2)] = \begin{bmatrix} \cos(2\varnothing_2) & 0 & j\sin(2\varnothing_2) \\ 0 & 1 & 0 \\ j\sin(2\varnothing_2) & 0 & \cos(2\varnothing_2) \end{bmatrix} \quad (9)$$

分别作用于相干矩阵，得到

$$\langle [T(\varnothing_1)] \rangle = [R(\varnothing_1)] \langle [T(\theta)] \rangle [R(\varnothing_1)]^{-1} \quad (10)$$

$$\langle [T(\varnothing_2)] \rangle = [R(\varnothing_2)] \langle [T(\theta)] \rangle [R(\varnothing_2)]^{-1} \quad (11)$$

式中，角度 $\varnothing_1$ 和 $\varnothing_2$ 是通过分别最小化 $T_{33}(\varnothing_1)$ 和 $T_{33}(\varnothing_2)$ 分量得到的，其约束结果为： $T_{23}(\varnothing_1) = 0$ 和 $\text{Im}\{T_{13}(\varnothing_2)\} = 0$ 。

线性水平 (H) 极化的电磁波在传输时接收的 Stokes 向量 $G_H^r = [g_{H1}^r, g_{H2}^r, g_{H3}^r, g_{H4}^r]^T$ ，传输时 $G_H^t = [1, 1, 0, 0]^T$ ，线性垂直 (V) 极化的电磁波在传输时接收的 Stokes 向量 $G_V^r = [g_{V1}^r, g_{V2}^r, g_{V3}^r, g_{V4}^r]^T$ ，传输时为 $G_V^t = [1, -1, 0, 0]^T$ ，上标 r 和 t 分别表

示接收波和发射波，它们通过 Mueller 矩阵 $\langle [M] \rangle$ 相关联，是从 3×3 相干矩阵 T 中得到的，是在传输和接收的 Stokes 向量之间的线性映射，即

$$G_H^r = \langle [M] \rangle G_H^t \quad (12)$$

$$G_V^r = \langle [M] \rangle G_V^t \quad (13)$$

电磁波的偏振状态通过偏振度 m ($0 \leq m \leq 1$) 来描述，其定义为偏振部分的平均强度与总强度的比值。当 $m=1$ 时，对应完全偏振波， $m=0$ 时，对应完全非偏振波，其余情况则为部分偏振。对于水平垂直极化传输情形，接收波的极化度分别为

$$m_H = \frac{\left(\sum_{i=2}^4 (g_{Hi}^r)^2 \right)^{\frac{1}{2}}}{g_{H1}^r} \quad (14)$$

$$m_V = \frac{\left(\sum_{i=2}^4 (g_{Vi}^r)^2 \right)^{\frac{1}{2}}}{g_{V1}^r} \quad (15)$$

据此得到 EDoP，为便于公式表达，本文公式以 m_E 表示 EDoP：

$$m_E = \left(\frac{m_H^2 + m_V^2}{2} \right)^{\frac{1}{2}} \quad (16)$$

3.4.2 融合有效极化度的无模型极化分解

融合 EDoP 的无模型三分量和四分量分解方法过程见图 3。在实际应用中，森林冠层等自然目标通常具有复杂且非规则的空间取向，其散射响应容易受到目标取向与观测几何关系变化的影响。为减弱目标取向变化对极化参数估计的影响，使分解结果更稳定地反映散射体自身的极化特性，本文在无模型三分量分解的框架下，首先将相干矩阵 T 通过 $R(\theta)$ 矩阵进行旋转，得到 $T(\theta)$ 矩阵，并结合 m_E 重新计算目标特征参数 θ_E ，同时将 Barakat 极化度替换为 EDoP，故此总功率 (Span) 可分解为：二次散射功率、表面散射功率和体散射功率。该分解保持了功率守恒，并保证各分量非负。进一步地，将 $T(\theta)$ 矩阵转换为 Kennaugh 矩阵 K ，并引入目标散射不对称性参数 τ_E (式 (5))，由此可在无模型四分量分解框架下 (Dey 等，2021b)，将总功率分解为 4 个分量：二次散射功率、表面散射功率、体散射功率和螺旋散射功率。此外， P_r 表示剩余散射功率 (residual scattering power)，即扣除体散射功率以及螺旋散射功率后，用于进一步分配为表面散射功率和二次散射功率的中间功率项。




图3 基于有效极化度的无模型分解方法流程

Fig. 3 Flowchart of the improved model-free decomposition method with EDoP

3.5 森林 AGB 定量反演模型与精度评价

本文基于前述3种极化分解方法所提取的特征及其通过对数和比率变换获得的衍生参数 (Long 等, 2019), 采用随机森林 RF (Random Forest)、支持向量回归 SVR (Support Vector Regression)、多元线性回归 MLR (Multiple Linear Regression)、K 最近邻模型 KNN (K-nearest neighbor) 4 种机器学习模型, 建立森林 AGB 估测模型 (De Castro-Filho 和 Bias, 2021)。

在模型构建过程中, 为保证不同机器学习模型反演结果的可靠性与可比性, 对 RF、SVR 及 KNN 模型的关键参数进行了优化。其中, RF 模型通过交叉验证对树的数量 ($n_{\text{estimators}}$) 及最大特征数 (max_features) 等参数进行调优; SVR 模型采用径向基函数 RBF (Radial Basis Function) 作为核函数, 并通过网格搜索方法对惩罚参数 C 与核函数参数 γ 进行优化; KNN 模型通过交叉验证方式选取最优邻居数 K , 以避免参数选择不当导致的过拟合或欠拟合问题。同时, 在模型构建阶段引入前向特征选择方法获取最优特征组合, 以减少冗余信息和多重共线性影响。多元线性回归模型采用普通最小二乘法构建, 并结合特征筛选以提高模型稳定性 (Gao 等, 2018)。

此外, 为充分利用有限样本并获得更稳定的估测结果, 模型参数优化与性能评估均基于留一交叉验证 LOOCV (Leave-One-Out Cross Validation) 框架完成。以各研究区地面实测 AGB 样本为因变量、极化分解特征为自变量, 并通过决定系数 (R^2)、均方根误差 RMSE (Root Mean Square Error) 和 rRMSE 等指标评价模型性能 (Wang 等, 2022)。

4 结果分析

4.1 改进的无模型极化分解能量分布结果

本文采用像元比例平均聚合方法计算区域散射能量占比, 以获取更为稳定的区域散射统计结果 (图4)。在3个研究区的三分量与四分量极化分解结果中, 不同极化分解方法的散射能量均以体散射 VOL (volume scattering) 为主导成分。其中, 基于模型的分解方法中 VOL 能量占比最高 (50%—70%), 表明传统方法在假设理想几何结构条件下倾向于高估 VOL 能量; 由于取消了几何约束, 无模型分解方法提取的 VOL 能量占比显著降低, 二次散射 DBL (double-bounce scattering) 与表面散射 ODD (odd-bounce scattering) 能量占比相应上升, 四分量中部分原属 VOL 的能量还被重新分配至螺旋散射 HLX (helix scattering)。改进的无模型

分解进一步强化了该趋势, VOL 能量占比降至约 30%, 其中向 DBL 的能量再分配幅度最大, 提升约 20%。结果表明, 传统基于模型分解方法对 VOL 存在系统性高估, 无模型分解方法虽缓解了 VOL 的误分配问题, 但对 DBL 射信号有所抑制; 而改

进的无模型分解方法通过引入新的极化度量指标, 有效削弱了 VOL 的高估倾向, 显著增强了 DBL 与 ODD 的表征能力, 使散射能量分布更符合实际森林结构的物理特性, 从而在复杂散射环境中表现出更优的物理一致性和分解稳定性。




图4 各散射分量能量占比结果(MB、MF、IMF 分别表示基于模型分解、无模型分解和改进无模型分解)

Fig. 4 Energy proportion of each scattering component (MB, MF, IMF represent model-based decomposition, model-free decomposition, and improved model-free decomposition, respectively)

4.2 极化分解特征与森林 AGB 的敏感性分析

为了揭示不同极化分解特征对 AGB 的敏感性, 本文计算了 3 种分解方法 (基于模型分解、无模型分解、改进无模型分解) 提取的特征与实测森林 AGB 的皮尔逊 (Pearson) 相关系数绝对值, 并绘制相关性系数分布图 (图 5)。在 3 个具有明显林分类型和结构差异的研究区中, 极化分解特征与森林 AGB 的相关性表现出清晰且一致的规律。总体来看, 传统基于模型的分解方法对森林 AGB 的敏感性较低, VOL 散射分量相关系数普遍低于 0.40, DBL 散射分量相关系数接近 0。无模型分解方法显著改善了特征表现, VOL 散射分量提升至 0.46—0.55,

DBL 散射分量上升至 0.32—0.44。引入有效极化度的改进无模型分解方法在所有森林类型中均取得了最优结果: 在针叶林中, VOL 散射分量和 DBL 散射分量分别达到 0.59—0.63 和 0.45—0.52; 在针阔混交林中, VOL 散射分量提高至 0.76, DBL 散射分量稳定在 0.50—0.67; 而在以针阔混交林为主、结构异质性更高的林分中, VOL 散射分量保持在 0.59—0.61, DBL 散射分量为 0.40—0.44。结果表明, 改进的无模型分解方法能够增强极化特征的稳定性和敏感性, 更稳健地刻画不同散射机制, 并在林分结构复杂的情况下显著强化特征与森林 AGB 之间的对应关系。




图5 极化分解特征与森林AGB的Pearson相关性系数(MB-3D、MF-3D、IMF-3D、MB-4D、MF-4D和IMF-4D分别表示基于模型、无模型和改进无模型的三分量与四分量分解方法)

Fig. 5 Pearson correlation coefficients between polarimetric decomposition features and forest aboveground biomass (MB-3D, MF-3D, IMF-3D, MB-4D, MF-4D, and IMF-4D denote model-based, model-free, and improved model-free decomposition with three or four components, respectively)

4.3 融合有效极化度的无模型极化分解的森林AGB估测结果


为对比基于模型、无模型及融合有效极化度的改进无模型的三、四分量分解方法在森林AGB估测中的精度差异,3个研究区均采用三景全极化SAOCOM数据提取的极化分解特征及其组合特征,结合前向特征筛选与MLR、KNN、SVR、RF等4种机器学习模型进行建模。模型表现通过 R^2 、RMSE

及rRMSE进行评价(图6)。


由于3个研究区林分结构和生物量差异显著,不同极化分解方法在森林AGB估测精度上呈现出不一致的规律性。传统基于模型的极化分解方法提取的极化特征估测森林AGB的精度最低, R^2 普遍低于0.40, RMSE值范围为30—40 t/hm²。相比之下,无模型的极化分解方法提取的极化特征在各研究区的估测精度均有一定改善, R^2 均提升0.05—

0.20, RMSE和rRMSE值相应下降。引入有效极化度的无模型极化分解方法提取的极化特征估测森林AGB的表现最优,对比无模型分解方法, R^2 进一步提升0.10—0.30, RMSE降低至23—35 t/hm², rRMSE


下降2—6个百分点。实验结果表明,本文提出的方法在不同森林类型中均显著提高了森林AGB估测的精度与稳定性,且在结构异质性较强的区域优势更加明显。




(a) 黄丰桥林场三分量分解(8月26日)
(a) Three-Decomposition of Huangfengqiao Forest Farm (Aug. 26)




(b) 黄丰桥林场三分量分解(9月3日)
(b) Three-Decomposition of Huangfengqiao Forest Farm (Sep. 3)




(c) 黄丰桥林场三分量分解(9月11日)
(c) Three-Decomposition of Huangfengqiao Forest Farm (Sep. 11)




(d) 黄丰桥林场四分量分解(8月26日)
(d) Four-Decomposition of Huangfengqiao Forest Farm (Aug. 26)




(e) 黄丰桥林场四分量分解(9月3日)
(e) Four-Decomposition of Huangfengqiao Forest Farm (Sep. 3)




(f) 黄丰桥林场四分量分解(9月11日)
(f) Four-Decomposition of Huangfengqiao Forest Farm (Sep. 11)




(g) 新田县三分量分解(10月13日)
(g) Three-Decomposition of Xintian County (Oct. 13)




(h) 新田县三分量分解(10月21日)
(h) Three-Decomposition of Xintian County (Oct. 21)




(i) 新田县三分量分解(10月29日)
(i) Three-Decomposition of Xintian County (Oct. 29)



(j) 新田县四分量分解(10月13日)
(j) 4-Decomposition of Xintian County (Oct. 13)



(k) 新田县四分量分解(10月21日)
(k) 4-Decomposition of Xintian County (Oct. 21)



(l) 新田县四分量分解(10月29日)
(l) 4-Decomposition of Xintian County (Oct. 29)




图6 不同极化分解方法在不同反演模型下估测森林AGB的统计结果(MB-3D、MF-3D、IMF-3D、MB-4D、MF-4D和IMF-4D分别表示基于模型、无模型和改进无模型的三分量与四分量分解方法)

Fig. 6 Statistical results of forest above-ground biomass (AGB) estimation obtained from different inversion models under various polarimetric decomposition methods (MB-3D, MF-3D, IMF-3D, MB-4D, MF-4D, and IMF-4D denote model-based, model-free, and improved model-free decomposition with three or four components, respectively)

为了定量评估不同极化分解方法所提取的极化特征在森林AGB反演中的表现与适用性,本研究采用SVR模型对3个研究区的森林AGB预测值与实测值进行了残差分析。整体上,传统基于模型的分解方法拟合效果较差,地面观测值和预测值的分布离散,存在显著的低AGB高估和高AGB低估现象, R^2 为0.11—0.38, RMSE为29.13—37.44 t/hm², rRMSE为30.17%—42.71%。无模型极化分解方法改善了地面观测值和预测值的分布规律,拟合线更接近1:1, R^2 提升0.03—0.15, RMSE减少0.71—3.60 t/hm², rRMSE下降0.65—5.05个百分点。引入有效极化度的无模型极化分解方法表现最佳, R^2 进一步提升0.02—0.34, RMSE减少0.53—7.28 t/hm², rRMSE下降0.65—6.69个百分点。实验结果表明,本文提出的融合有效极化度的无模型分解方法能够有效减弱低AGB高估和高AGB低估现象,提升森林AGB估测的精度和可靠性,尤其在复杂森林环境中表现出更强的适应性。

为了进一步评估不同极化分解方法提取的极化特征在森林AGB反演中的潜力,本文选择表现最优的三分量极化分解与SVR模型构建研究区森林AGB反演模型,并利用全极化SAOCOM影像绘制森林AGB反演结果图(图8)。实验结果表明,3种极化分解方法均能较好地反映森林AGB的空间分异格局,但在结构敏感性与估测稳定性方面表现存在显著差异。模型分解方法的反演结果整体较为平滑,对高AGB区域存在低估倾向,而对低AGB区域则出现一定程度的高估,并缺乏明显的梯度变化特征。无模型分解方法在低AGB区具有更高的分辨能力,能够有效识别局部林分结构差异,缓解低值高估的饱和现象,但其结果引入了较多噪声,空间连续性相对较差。相比之下,改进的无模型分解方法在3个研究区域的反演结果中均表现出更优的空间一致性,AGB分布呈现清晰的梯度特征,且估测值的空间格局更契合地形起伏与林分结构的实际变化,显示出其在复杂地貌与多

样化林分结构条件下进行精细化森林 AGB 反演的良好应用潜力。

从不同森林类型条件下的反演结果来看，各极化分解方法的性能差异与林分结构特征及其主导的极化散射机制密切相关。在以针叶树种占优势的林分中，由于树干直立性强、冠层结构相对规整，3 种方法反演的 AGB 空间格局总体一致，但在局部高值比例与空间平滑程度上仍存在差异。其中，基于模型的分解方法倾向于给出更平滑且相对较高的 AGB 分布，而无模型及改进无模型方法对局部结构变化更为敏感。在针阔混交林或以针阔

混交林为主、结构异质性更强的林分中，不同方法之间的差异明显增强。由于冠层结构复杂、散射机制多样，VOL 与 DBL 等过程呈现出较强的随机性与去极化特征，使得基于固定几何假设的模型分解方法更易受到模型假设约束的影响。相比之下，无模型极化分解方法不依赖具体散射模型假设，能够更灵活地刻画复杂散射能量的分布。进一步融合有效极化度的改进方法，在噪声和去极化效应较强的条件下表现出更稳定的空间分布特征，从而在复杂林分条件下获得更稳定的反演结果。




图7 森林 AGB 实测值与预测值散点图(黄丰桥林场、新田县和长株潭绿心区散点图分别采用9月3日、10月13日和9月27日获取的 SAR 影像数据绘制,MBD、MFD 和 IMFD 分别表示基于模型分解、无模型分解和融合有效极化度的改进无模型分解; RMSE 单位为 t/hm²)

Fig. 7 Scatter plots of measured and predicted values of forest above-ground biomass (AGB) (MBD, MFD, and IMFD denote model-based decomposition, model-free decomposition, and improved model-free decomposition incorporating EDoP, respectively. The scatter plots for Region 1, Region 2, and Region 3 were generated using SAR images acquired on Sep. 3, Oct. 13, and Sep. 27, respectively; the unit of RMSE is t/hm²)




图8 森林 AGB 反演结果

Fig. 8 Forest above-ground biomass (AGB) inversion results

5 结 论

针对传统无模型极化分解中核心参数—Barakat 极化度在复杂森林环境中受噪声与去极化效应影响,导致极化分解特征易出现偏差的问题,本文在其分解框架中引入 EDoP,提出了改进的无模型极化分解方法。以湖南省3个典型森林区域为研究对象,以L波段全极化SAOCOM影像为研究数据,结合前向特征筛选与机器学习模型,构建森林AGB估测模型,定量评估改进方法在复杂森林环境中进行AGB反演的稳健性与适用性。主要研究结论包括以下3点。

(1) EDoP有效抑制了噪声与去极化效应导致的能量估计偏差,改善了VOL与DBL分量的功率平衡。相比传统方法,VOL能量占比由约60%降至约30%,DBL能量占比提升约20%,使极化特征与AGB之间的物理对应关系更加稳定,增强了改进无模型分解方法在非理想散射条件下的物理一致性。

(2) 融合EDoP的无模型极化分解特征与森林AGB均表现出较高的敏感性。相比传统无模型分解方法,VOL和DBL散射分量与AGB的相关性平均提升0.10—0.15,显著增强了极化特征对林分结构变化的响应能力。

(3) 融合EDoP的无模型极化分解方法提取的极化特征估测森林AGB的精度均表现最优, R^2 普遍提升至0.40—0.60, RMSE为24—35 t/hm², rRMSE为22%—35%,其中,在黄丰桥研究区采用融合EDoP的无模型三分量极化分解方法并结合SVR模型所得到的估测结果精度最高, R^2 达到0.50, RMSE为24.93 t/hm², rRMSE为22.88%。研究区的森林AGB反演结果表明,本文提出的方法反演的森林AGB空间分布更加合理,高AGB区饱和效应明显减弱,低估与高估区域均得到有效改善。

总体而言,融合EDoP的无模型极化分解方法强化了极化特征对散射纯度与去极化特性的稳健表征,提升了全极化SAR数据反演森林AGB方法的稳定性与可移植性。未来研究将进一步结合多时相、多源遥感数据,探索该方法在森林资源时序变化监测和区域碳储量估算中的应用潜力。

参考文献(References)

- Bhattacharya A, Singh G, Manickam S and Yamaguchi Y. 2015. An adaptive general four-component scattering power decomposition with unitary transformation of coherency matrix (AG4U). *IEEE Geoscience and Remote Sensing Letters*, 12(10): 2110-2114 [DOI: 10.1109/LGRS.2015.2451369]
- Bhattacharya A and Surendar M. 2016. Enhanced target characterization and improved scattering power decompositions using the optimized coherency matrix from full-polarimetric SAR data. *Remote Sensing Letters*, 7(11): 1073-1082 [DOI: 10.1080/2150704X.2016.1217439]
- Cartus O and Santoro M. 2019. Exploring combinations of multi-temporal and multi-frequency radar backscatter observations to estimate above-ground biomass of tropical forest. *Remote Sensing of Environment*, 232: 111313 [DOI: 10.1016/j.rse.2019.111313]
- Cloude S R and Pottier E. 1996. A review of target decomposition theorems in radar polarimetry. *IEEE Transactions on Geoscience and Remote Sensing*, 34(2): 498-518 [DOI: 10.1109/36.485127]
- Cloude S R and Pottier E. 1997. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 35(1): 68-78 [DOI: 10.1109/36.551935]
- De Castro-Filho C A P and Bias E. 2021. Comparison between quantitative and qualitative theme-feature forest biomass estimation models built over SAR Data. *International Journal of Advanced Engineering Research and Science*, 8(7): 367-386 [DOI: 10.22161/ijaers.87.41]
- Dey S, Bhattacharya A, Frery A C, Lopez-Martinez C and Rao Y S. 2021b. A model-free four component scattering power decomposition for polarimetric SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 3887-3902 [DOI: 10.1109/JSTARS.2021.3069299]
- Dey S, Bhattacharya A, Ratha D, Mandal D and Frery A C. 2021a. Target characterization and scattering power decomposition for full and compact polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5): 3981-3998 [DOI: 10.1109/TGRS.2020.3010840]
- Freeman A and Durden S L. 1998. A three-component scattering model for polarimetric SAR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 36(3): 963-973 [DOI: 10.1109/36.673687]
- 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]
- Han W T, Fu H Q, Zhu J J, Xie Q H and Zhang S R. 2022. Orthogonal scattering model-based three-component decomposition of polarimetric SAR data. *Remote Sensing*, 14(17): 4326 [DOI: 10.3390/rs14174326]
- Hu Y F, Nie Y H, Liu Z H, Wu G M and Fan W Y. 2023. Improving the potential of coniferous forest aboveground biomass estimation by

- Integrating C- and L-band SAR data with feature selection and non-parametric model. *Remote Sensing*, 15(17): 4194 [DOI: 10.3390/rs15174194]
- Karachristos K, Koukiou G and Anastassopoulos V. 2024. A review on PolSAR decompositions for feature extraction. *Journal of Imaging*, 2024, 10(4): 75 [DOI: 10.3390/jimaging10040075]
- Kumar S, Garg R D, Govil H and Kushwaha S P S. 2019. PolSAR-decomposition-based extended water cloud modeling for forest aboveground biomass estimation. *Remote Sensing*, 11(19): 2287 [DOI: 10.3390/rs11192287]
- Li Z Y, Liu Y M, Liu X H, Xing S Q, Lv H F and Wu G Q. 2023. Improved general polarimetric model-based decomposition for coherency matrix. *Remote Sensing*, 15(11): 2899 [DOI: 10.3390/rs15112899]
- Li Z Y, Zhao L, Li K, Chen E X, Wan X X and Xu K P. 2020. A survey of developments on forest resources monitoring technology of synthetic aperture radar. *Journal of Nanjing University of Information Science and Technology (Natural Science Edition)*, 12(2): 150-158 (李增元, 赵磊, 李堃, 陈尔学, 万祥星, 徐昆鹏. 2020. 合成孔径雷达森林资源监测技术研究综述. *南京信息工程大学学报(自然科学版)*, 12(2): 150-158) [DOI: 10.13878/j.cnki.jnuist.2020.02.002]
- Long J P, Lin H, Wang G X, Sun H and Yan E P. 2019. Mapping growing stem volume of Chinese fir plantation using a saturation-based multivariate method and quad-polarimetric SAR images. *Remote Sensing*, 11(16): 1872 [DOI: 10.3390/rs11161872]
- Manickam S, Bhattacharya A, Singh G and Yamaguchi Y. 2017. Estimation of snow surface dielectric constant from polarimetric SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(1): 211-218 [DOI: 10.1109/JSTARS.2016.2588531]
- Muhuri A, De S, Manickam S, Dhingra S, Hariharan S, Maity A, Ratha D and Bhattacharya A. 2016. Novel scattering power decomposition techniques for full and compact polarimetric SAR data. *National Symposium on Recent Advances in Remote Sensing and GIS with Special Emphasis on Mountain Ecosystems and Annual Conventions of Indian Society of Remote Sensing and Indian Society of Geomatics*. Dehradun, India: Indian Society of Remote Sensing and Indian Society of Geomatics. [DOI: 10.5281/ZENODO.1322885]
- Nie Y H, Sa R, Chumachenko S, Hu Y F, Wang Y Z and Fan W Y. 2024. Inversion of forest aboveground biomass in regions with complex terrain based on PolSAR data and a machine learning model: radiometric terrain correction assessment. *Remote Sensing*, 16(12): 2229 [DOI: 10.3390/rs16122229]
- Nunziata F, Gambardella A and Migliaccio M. 2013. On the degree of polarization for SAR sea oil slick observation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 78: 41-49 [DOI: 10.1016/j.isprsjprs.2012.12.007]
- Peng C, Fang C, Long J P, Zhang T C, Zheng H N and Ye Z L. 2025. Estimation of forest aboveground biomass using multitemporal quad-polarimetric PALSAR-2 SAR data by model-free decomposition approach in planted forest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18: 13519-13537 [DOI: 10.1109/JSTARS.2025.3572083]
- Ratha D, Manickam S and Bhattacharya A. 2017. Improvement of PolSAR decomposition scattering powers using a relative decorrelation measure. *Remote Sensing Letters*, 8(4): 340-349 [DOI: 10.1080/2150704X.2016.1271159]
- Santoro M and Cartus O. 2018. Research pathways of forest above-ground biomass estimation based on SAR backscatter and interferometric SAR observations. *Remote Sensing*, 10(4): 608 [DOI: 10.3390/rs10040608]
- Vahimaa P and Tervo J. 2004. Unified measures for optical fields: degree of polarization and effective degree of coherence. *Journal of Optics A: Pure and Applied Optics*, 6(3): S41-S44 [DOI: 10.1088/1464-4258/6/3/007]
- Wang J J, Wu F, Shang J L, Zhou Q, Ahmad I and Zhou G S. 2022. Saline soil moisture mapping using Sentinel-1A synthetic aperture radar data and machine learning algorithms in humid region of China's east coast. *Catena*, 213: 106189 [DOI: 10.1016/j.catena.2022.106189]
- Wang M, Wang Z Y, Yang C, Yang S Y and Gao Y T. 2019. Polarimetric SAR data classification via reinforcement learning. *IEEE Access*, 7: 137629-137637 [DOI: 10.1109/ACCESS.2019.2939232]
- Wang T and Zhao D M. 2010. Polarization-induced coherence changes of an electromagnetic light wave on scattering. *Optics Letters*, 35(18): 3108-3110 [DOI: 10.1364/OL.35.003108]
- Yamaguchi Y, Moriyama T, Ishido M and Yamada H. 2005. Four-component scattering model for polarimetric SAR image decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 43(8): 1699-1706 [DOI: 10.1109/TGRS.2005.852084]
- Yu Q F, Yue C R, Luo H B, Luo G F, Duan Y F, Sun M Q, Heng C Z and Xu T S. 2024. Forest AGB estimation based on airborne L-band full-polarization UAVSAR. *Forest Engineering*, 40(5): 17-29 (余琼芬, 岳彩荣, 罗洪斌, 罗广飞, 段云芳, 孙妙琦, 恒承志, 徐天蜀. 2024. 基于机载 L 波段全极化无人机合成孔径雷达的森林地上生物量估测. *森林工程*, 40(5): 17-29) [DOI: 10.7525/j.issn.1006-8023.2024.05.003]
- Zeng P, Zhang W F, Li Y, Shi J M and Wang Z H. 2022. Forest total and component above-ground biomass (AGB) estimation through C- and L-band polarimetric SAR data. *Forests*, 13(3): 442 [DOI: 10.3390/f13030442]
- Zhang J X, Zhou C, Zhang G, Yang Z G, Pang Z H and Luo Y F. 2024. A novel framework for forest above-ground biomass inversion using multi-source remote sensing and deep learning[J]. *Forests*, 15(3): 456 [DOI: 10.3390/f15030456]
- Zhang W F, Zhao L X, Li Y, Shi J M, Yan M, and Ji Y J. 2022. Forest above-ground biomass inversion using optical and SAR images based on a multi-step feature optimized inversion model. *Remote Sensing*, 14(7): 1608 [DOI: 10.3390/rs14071608]
- Zolkos S G, Goetz S J and Dubayah R. 2013. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. *Remote Sensing of Environment*, 128: 289-298 [DOI: 10.1016/j.rse.2012.10.017]

Forest above-ground biomass inversion using full-polarimetric SAR data with integrated effective degree of polarization

HUANG Zijia^{1,2}, LONG Jiangping^{1,2}, ZHAO Deliang³, LIN Hui^{1,2}, SUN Hua^{1,2}, ZHANG Tingchen^{1,2}

1. Hunan Provincial Key Laboratory of Forestry Remote Sensing Based Big Data & Ecological Security,

Central South University of Forestry and Technology, Changsha 410004, China;

2. Hunan Engineering Research Center for Monitoring of Natural Ecosystem Carbon Sinks, Changsha 410004, China;

3. Shandong GEO-Surveying & Mapping Institute, Ji'nan 250003, China

Abstract: Full-polarimetric Synthetic Aperture Radar (SAR) data are highly effective for characterizing the vertical structure of forest canopies and play a crucial role in estimating forest above-ground biomass (AGB). An appropriate polarimetric decomposition method is essential for effectively extracting key polarization features and constructing high-accuracy quantitative inversion models. However, under complex forest canopy conditions, traditional model-free decomposition based on the 3D Barakat degree of polarization is prone to errors caused by depolarization, noise, and variations in observation geometry. These limitations reduce the stability and generalization ability of polarimetric features in AGB retrieval.

To address these issues, this study proposed an improved model-free polarimetric decomposition method by replacing the conventional 3D Barakat degree of polarization with the effective degree of polarization (EDoP), which was used to regulate scattering power allocation among different scattering components. L-band full-polarization SAOCOM images from three representative forest regions in Hunan Province, China, were used as data sources. Three decomposition strategies—model-based, traditional model-free, and the proposed EDoP-integrated model-free decomposition—were applied to extract polarization features. Subsequently, forward feature selection was combined with four machine learning regression models, including multiple linear regression, K-nearest neighbor, support vector regression, and random forest, to perform quantitative AGB inversion.

Results demonstrate that the EDoP-integrated decomposition significantly improves the power allocation among scattering mechanisms. The proportion of volume scattering decreased from approximately 40% to 30%, while the double-bounce scattering component increased by about 20%, effectively mitigating energy estimation bias caused by noise and depolarization. This adjustment enhanced the physical consistency between scattering components and forest AGB, particularly in heterogeneous canopy structures. Compared with the traditional model-free approach, the proposed method achieved stronger correlations between the extracted polarimetric features and AGB. In quantitative inversion, it increased the coefficient of determination by 0.15–0.30 and reduced the relative root mean square error by 4%–7%. The spatial distribution maps of predicted AGB were also more consistent with actual forest patterns, with less underestimation and overestimation and a weaker saturation effect in high-biomass regions.

This study verifies the robustness and transferability of EDoP-integrated model-free decomposition in complex forest environments. The proposed approach effectively suppresses decomposition bias and enhances the accuracy and stability of AGB retrieval. By mitigating the AGB saturation effect and improving model generalization in heterogeneous forest stands, it offers a promising approach for large-scale, high-precision monitoring of forest biomass and carbon storage using polarimetric SAR data.

Key words: forest Above-Ground Biomass (AGB), Effective Degree of Polarization (EDoP), model-free decomposition, machine learning, SAOCOM

Supported by National Natural Science Foundation of China (No. 32171784, 42030112)