

利用地理 机森林绘制地上生物 :克服大尺度区域的 空 平稳性

张紫红^{1 2} 石铁柱^{1 2}

(1.深圳大学建筑与城市规划学院 广东省深圳市 518000; 2.深圳大学自然资源部大湾区地理环境监测重点实验室 广东省深圳市 518000;)

摘 要:【目的】森林地上生物量(AGB)信息及其驱动因素对指导森林管理活动至关重要。然而,AGB 估算结果仍存在较大的不确定性,小尺度范围内 AGB 驱动机制的空间变异研究较少,这将阻碍特定地点森林的精准管理。【方法】我们选择内蒙古自治区作为研究区域,该地区东西跨度大,植被、气候、土壤和地形变化明显,空间非平稳性较强。我们在该区域建立了四种 AGB 估算模型,分别是地理随机森林(GRF)、随机森林、梯度增强回归和支持向量回归模型;我们以 GRF 方法建立了 AGB 驱动模型,并分析驱动因子对 AGB 影响力在空间上的变化情况。【结果】在 32 个 AGB 预测因子中,有 14 个特征具有显著的空间非平稳性,涉及光谱和环境变量。在驱动因子中,4 个因子与 AGB 的驱动模式存在明显的空间波动。GRF 方法在随机交叉验证和空间交叉验证中的 R^2 值分别为 0.622 和 0.481,均优于随机森林、梯度增强回归和支持向量回归等传统机器学习方法。此外,GRF 的不确定性更小,稳定性更高。物种多样性是 AGB 最主要的驱动因子,和生长季内月降水量的分布方差(SDP)因子类似,影响力在整个研究区较为均匀的;坡度和生长期总降水量(GSP)的驱动力呈明显的梯度变化。【结论】在内蒙古西部地区,由于坡度对 AGB 的影响较大,因此应优先选择坡度较低的区域进行植树。在东北地区,坡度的影响相对较小,但应特别注意极端降水事件对 AGB 的影响,并加强对低洼易涝地区的监测,防止树木因土壤表面积水而死亡。此外,建议在所有区域避免单一树种种植,优先考虑多物种混合种植,以提高生态系统的稳定性和适应性。

关键词: 地上生物量; 森林生态系统; 空间非平稳性; 地理随机森林; 内蒙古自治区;

Improving Forest Management Precision: Unveiling Spatial Non-Stationarity in Aboveground Biomass and Driving Factors

Zhang ZiHong^{1 2} Shi TieZhu^{1 2}

(1. School of Architecture and Urban Planning, Shenzhen University 518000; 2. Key Laboratory of Geographical Environment Monitoring in Greater Bay Area, Department of Natural Resources, Shenzhen University 518000;)

Abstract: 【Objective】Forest above-ground biomass (AGB) information and its drivers are crucial to the formulation of forest management activities. However, there are still large uncertainties in the estimation results of AGB, and few studies focus on the spatial variation of AGB driving mechanisms at small scales, which will hinder the precise forest management at specific locations. 【Method】We choose Inner Mongolia Autonomous Region (IMAR) as the research area, which has a large distance from east to west, obvious changes in vegetation, climate, soil and topography, and strong spatial non-stationarity. We established four AGB estimation models in this region, namely geographical random forest (GRF), random forest, gradient enhanced regression and support vector regression model. We establish the AGB driving model with GRF method, and analyze the change of the influence of driving factors on AGB in space. 【Result】Among the 32 AGB predictors, 14 features have significant spatial non-stationarity, involving spectral and environmental variables. Among the driving variables, 4 factors are spatially different from the driving mechanism of AGB. The GRF method achieved R^2 values of 0.622 and 0.481 in random

and spatial cross-validation, respectively, outperforming traditional machine learning methods such as Random Forest (RF), Gradient Boosting Regressor (GBR), and Support Vector Regression (SVR). Furthermore, GRF is less uncertain and more stable. Species diversity is the most important driving factor of AGB, and its influence is similar to the variance of monthly precipitation distribution in the growing season (SDP), and their influence is relatively uniform in the whole study area. The driving force of slope and total precipitation showed significant gradient change during the growth period. 【Conclusion】 In the western region of IMAR, because the change of slope has a great impact on AGB, the area with low slope should be preferred for planting trees. In the northeast region, the influence of slope is relatively small, but special attention should be paid to the impact of extreme precipitation events on AGB, and monitoring of low-lying areas prone to waterlogging should be strengthened to prevent trees from dying due to excessive waterlogging. In addition, it is recommended to avoid monocarpy planting in all regions, and prioritize multi-species mixed planting to improve the stability and adaptability of ecosystems.

Key words: above-ground biomass; forest ecosystems; spatial non-stationarity; geographical random forest; Inner Mongolia.

森林生态系统作为全球碳平衡的组成部分, 具有将二氧化碳储存在树木和土壤中的能力。森林生物量是研究森林生态系统与大气之间碳交换的基本参数, 反映了森林与环境之间的物质循环和能量流动。地上生物量(AGB)通常定义为地上活物质或死物质的静态干质量, 以单位面积的质量表示(Ma 等, 2021; Jin 等, 2022)。它是最容易受到森林经营影响的碳库(Fahey 等, 2010; Erb 等, 2018)。土地转换、造林、森林采伐等典型的森林管理干预措施, 直接影响树木密度, 从而改变 AGB。反过来, AGB 也为森林管理者提供宝贵的见解, 以评估森林生态系统的现状, 为森林管理活动的最佳时间、地点和技术决策提供信息。因此, 定量描述 AGB 并确定 AGB 变化背后的驱动因素是森林管理者的基本任务。

基于地面测量数据构建 AGB 预测模型或驱动模型, 获取 AGB 分布信息或分析其驱动机理, 已被广泛研究和应用。然而, 我们发现了两个研究空白: AGB 信息的可靠性(Araza 等, 2022)和 AGB 驱动模式的空间变化。这些研究的空白可能会误导森林管理战略的制定, 妨碍森林管理活动的精确规划, 并导致政策不适合当地环境情况。AGB 估计的准确性主要受遥感传感器数据类型的影响, 其次是建模方法(Fassnacht 等, 2014), 然而目前建模方法仍旧不能完全克服空间非平稳性问题。空间非平稳性是指在不同的空间位置上自变量和因变量之间关系的变化(Stewart Fotheringham 等, 1996; Propastin, 2009; Finley, 2011)。此外, 在局部或区域尺度上, 气候、地形、生物和土壤类型等特征已被证明会影响 AGB(Pan 等, 2013)。然而, 同种因素对 AGB 的响应模式在不同空间区域存在差异, 但是关于驱动模式的空间分异研究较少。

地理随机森林(Geographically Random Forest, GRF) (Georganos 等, 2021)是一种综合了地理加权回归 (Geographical weighted regression, GWR) 和随机森林 (Random Forest, RF) 模型优点的方法。GRF 由多个局部位置的随机森林模型组成, 它考虑到了数据之间的空间自相关性, 每个局部模型使用附近的样本点进行训练。目前, GRF 在森林 AGB 定量回归中的应用较少, 研究多集中在滑坡易感性(Dai 等, 2023)、人口估算、家庭收入(Georganos & Kalogirou, 2022)、交通事故(Gu 等, 2023)等方面。

因此, 本研究旨在利用成本更低、覆盖速度更快的传感器数据, 引入 GRF 模型克服空间非平稳性, 降低估算不确定性, 从而在环境异质性显著的大范围研究区域内绘制 AGB 的分布。我们通过使用 GRF 模型分析不同空间位置的 AGB 驱动力, 旨在促进森林管理活动的精确规划, 并最终为制定更符合当地条件的管理政策提供信息。

1 研究区概况

内蒙古自治区位于中国北部(东经 97°12'~126°04', 北纬 37°24'~53°23'), 面积约 118.3 万平方公里(图 1), 是中国森林面积最大的自治区, 森林面积达 4.08 亿亩, 有松树、桦树、杨树、榆树等丰富的树种。内蒙古自治区具有很强的环境异质性。从西到东, 内蒙古的生态系统从沙漠过渡到草原, 最后到森林。

内蒙古自治区的年平均气温为-4.5 ~ 9.8℃，年平均降水量为 50 ~ 450 毫米。内蒙古自治区气候类型多样，包括冷沙漠气候、冷半干旱气候、受季风影响的湿润-中亚热带气候、湿润亚热带高原气候和湿润亚热带冷高原气候(Song 等, 2020)。




图 1 内蒙古自治区的国际气象站、采样样点的空间分布以及土地覆盖类型示意图，其中（a）图描述了研究区域的月平均降水及温度情况

Fig. 1 Location of the study area and spatial distributions of international weather stations, sample sites and land cover types in the Inner Mongolia Autonomous Region. The graph (a) inserted depicts the average monthly precipitation and temperature in the study area.

2 研究方法

2.1 AGB 地 调查

我们在 2021-2023 年的 7、8 月共采集 310 个样地，覆盖了 2 种森林类型、3 个植被带、5 种气候类型和 7 种土壤类型。在采样之前，我们使用遥感图像大致确定样地位置。到达现场后，使用全球定位系统精确记录地块位置。我们根据实际情况选择地块大小为 30m*20m 或 20m*50m。对于每个样地，对胸径大于 3cm 的活树测量树高和胸径(距土壤表面 1.3 m 处)，记录下树高、胸径、树龄、地理位置等相关信息。根据实测树木数据，利用异速生长方程(表 1) (Luo 等, 2019)计算 AGB。最后将每棵树的 AGB 估计值汇总到样地水平，并除以样地面积以产生密度估计值。这 310 个样本的分布如图 2 所示。此外，我们计算了每个样地的物种密度、基底面积、香农多样性(Ifo 等, 2016)和霍德里奇复杂度指数。我们利用这两个指标作为物种丰富度的指标来量化木本物种的多样性。

表 1. 每个树种的 AGB 异速生 方程

Tab. 1 Main allometric equations for the aboveground AGB calculation of each tree species

树种	AGB 异速生长方程(kg)
落叶松	$AGB = 0.0285 \cdot (D^2 \cdot H)^{0.9804} - 0.0017 \cdot (D^2 \cdot H)^{0.9804}$

其他类型	1.0793
桦树	$AGB = 0.0196*(D^{3.0264})-0.0060*(D^{2.9521})$
杨树	$lg(AGB)=-1.1740+2.5580*lg(D)$
栎树	$lg(AGB)=-0.9980+2.456*lg(D)$
榆树	$AGB = 0.0134*D^{2.7518}$
柳树	$AGB = 0.4439*D^{1.975}-0.1284*D^{1.8227}$
杉树	$lg(AGB)=-0.9545+0.8472*lg(D^2*H)$

AGB、D 和 H 代表地上生物量(kg)，胸径的直径(cm)和树高(m)。




图 2 AGB 的分布直方图

Fig. 2 Statistical histogram of the AGB for the forest in Inner Mongolia.

2.2 图像数据及其 处理

本研究利用了欧洲空间局提供的 Sentinel-1 和 Sentinel-2 数据。对于 Sentinel-2 的数据，我们使用了 Level-2A 的预处理产品，表示表面反射率，并进行了辐射、几何和大气校正。对 2021-2023 年 6 月至 8 月的 Sentinel-2 图像进行过滤，选择云量小于 4% 的图像。随后，对这些选择的图像进行中值合成处理，生成单一的合成图像，然后重新采样到 10 米的空间分辨率。

Sentinel-1 数据采用宽干涉模式获取，产品水平为 GRD。这一层的数据已经使用 sentinel -nel-1 工具箱进行了处理，得到了后向散射系数值。偏振模式包括垂直-垂直(VV)和垂直-水平(VH)。本研究选取了 2020 年 7 月 1 日至 2020 年 9 月 1 日的 Sentinel-1 数据。随后，将这些数据缝合、裁剪并重新采样以作进一步分析。

逐日降水数据由美国国家海洋和大气管理局提供。为了提高 AGB 对降水相关变量的敏感性，本研究提取了生长季降水（Growing Season Precipitation, GSP）和降水季节分布（Seasonal Distribution of Precipitation, SDP)两个指标(H. Xu & Wang, 2016)。GSP 指生长期（4 - 8 月）的累积降水量，SDP 为 4 - 8 月的月降水量分布方差系数。本研究对研究区域 2021 年至 2023 年的年度 GSP 和 SDP 图像做了均值处理，并将其作为 GSP 和 SDP 变量的最终输入。

逐日温度数据来源于哥白尼气候数据。本研究计算了从 2021 年到 2022 年每年的年平均温度(Annual Mean Temperature, AMT)图像。然后，对这两年的 AMT 图像进行平均，得到平均值，作为 AM T 变量的最终输入。降水和温度数据被重新采样到 10 米的空间分辨率。为了检验降水和温度遥感数据的可用性，本研究基于内蒙古的国际气象站数据(<https://data.cma.cn/>)进行遥感数据的验证。

其他辅助数据包括 IMAR 的行政边界数据、植被区划、土壤类型数据(<https://www.resdc.cn/>)、Cli Mond 气候区划数据(<https://www.climond.org/>)(Kriticos 等，2012)、欧空局的土地利用和土地覆盖数据以及航天飞机雷达地形任务的地形数据。

2.3 建模方法

2.3.1 机器学习 本研究采用了三种不同的机器学习算法:随机森林（Random Forest, RF）(Belgiu & Drăguț, 2016)、梯度增强回归（Gradient Boosting Regressor, GBR）(Friedman, 2001)和支持向量回归

(Support Vector Regression, SVR) (Smola & Schölkopf, 2004)。RF 是一种由多个决策树组成的集成学习方法, 其中每个决策树都使用子数据集进行训练。GBR 通过逐步添加和训练新的决策树来提升模型的性能, 每棵新树都拟合当前模型的残差, 以改进预测结果。SVR 将数据映射到一个高维空间, 以找到一个最优的超平面, 使观测值与超平面之间的距离最小。这三种机器学习都是离散数据的拟合, 不包含空间位置信息, 对于研究范围内的任何地理位置的预测, 都使用同一个模型进行预测, 属于全局模型。

2.3.2 地理随机森林 地理随机森林包括一个传统的全局 RF 模型和多个局部 RF 模型。在每个样本点的位置, 都建立了一个相对应的局部 RF 模型, 将该样本及其附近一定范围内的其他样本点作为该局部模型训练的数据集。GRF 模型的表达式为:

$$Y_i = a(u_i, v_i)X_i + e \quad i = 1: N \quad (1)$$

其中 i 表示第 i 样本点; N 为样本点总数; $a(u_i, v_i)X_i$ 指坐标位置为 (u_i, v_i) 的第 i 样本点的 GRF 模型预测值; Y_i 为第 i 样本点的观测值; e 指预测误差。

$$a(u_i, v_i)X_i = w_l x_i^l + w_g x^g \quad (2)$$

其中, x_i^l 表示局部 RF 模型在样本点 i 的预测值, w_l 表示局部 RF 预测值的权值; x^g 表示全局 RF 模型的预测值, w_g 表示该值对应的权值, $w_l + w_g = 1$; 对于未知点, x_i^l 表示该未知点最近的局部 RF 模型在该点的预测值。

2.4 实 设置

2.4.1 AGB 预测变量的特征选择 本研究在前人研究的基础上选取了 85 个解释变量, 大致可分为多光谱波段、植被指数、后向散射系数和自然属性四类(表 2)。从不同空间区域提取的最优特征可能会有所不同(Muro 等, 2022), 因此本研究在全局和局部层面进行了特征提取。在全局层面, 我们使用整个数据集提取特征, 从而得到全局最优特征;在局部层面, 我们使用特定子区域的数据提取特征, 从而得到局部最优特征。局部特征提取所在的子区域, 本研究考虑了四种分区方法:森林类型、植被分区、Köppen-Geiger 气候分区和土壤类型。

每个水平的提取方法包括三个步骤:(1)计算 Pearson 相关系数, 提取系数最高的前 10 个变量;(2)采用遗传算法获得建模变量的最优组合;(3)结合步骤(1)和(2)的结果建立随机森林模型, 得到排名前十的变量, 并将这十个变量认为是最终的最优特征集。

表 2. AGB 测模型中使用的 85 个解释变
Tab. 2 85 explanatory variables used in the AGB prediction models.

来源	类型	AGB 预测因子
Sentinel-2	多光谱波段	B1、B2、B3、B4、B5、B6、B7、B8、B8A、B9、B11、B12
	植被指数	SR、NDVI、NDVIre1、NDVIre2、NDVIre3、TNDVI、NDCI、EVI、DVI、TVI、MTVI、SAVI、SIPI、CARI、OSAVI、MSAVI、MSR、MSI、CIgreen、NVI、NDRE、NDWI1、NDWI2、GNDVI、WDVI、NDI45、MTCI、REP、RENDVI、REEVI、RDVI、MDI1、MDI2、PRI、TSGI、IRECI
Sentinel-1	后向散射系数	VV、VH、VV/VH、VV+VH、VH-VV
辅助数据	自然属性	Ele、slope、aspect AMT、SDP、GSP

2.4.2 AGB 驱动因子 本研究使用的 AGB 驱动因素如表 3 所示。我们基于这 8 个因子构建了 RF 模型, 并利用 GRF 提供的特征重要性作为因子影响的代理。GRF 能够在不同位置建立不同的本地 RF 模型, 每个本地 RF 模型都可以提供本地级别特定因素的特征重要性。因此, 我们可以量化不同空间区域特定因子对当地森林 AGB 的影响。这有助于森林管理机构识别跨空间区域的 AGB 驱动因素, 并制定最有利于加强 AGB 的措施。

表 3. AGB 动分析模型中使用的 8 个 动因素
Tab. 3 8 driving factors used in the AGB actuate analysis models.

类别	因子	描述
环境因子	Ele	高程
	Slope	坡度
	Aspect	坡向
	AMT	年平均气温
	GSP	生长季的总降水量
	SDP	生长季内月降水量的分布方差系数
生物因子	ShD	香农多样性
	HCI	霍德里奇复杂度指数

2.4.3 空间非平稳性检验 在 GWR 模型中，如果一个特征的回归系数在空间上变化显著，我们认为该变量与因变量之间的关系是空间非平稳的。GWR 模型的典型表达式为：

$$Y_i = \beta_{0i} + \sum_{j=1}^k \beta_{ji} X_{ji} + \varepsilon_i$$

(3)

式中 i 表示位置； Y_i 指 i 位置的因变量； β_{0i} 为截距； X_{ji} 表示第 j 个自变量在位置 i 处的值； β_{ji} 为 X_{ji} 的回归系数；k 为自变量个数； ε_i 为位置 i 处的误差项。

我们通过对“GWR 各变量的回归系数在整个研究区是否有显著变化”假设的统计检验来检验空间非平稳性的存在(Feng 等, 2021; Leung 等, 2000)。对第 k 个自变量的系数值 β_{ik} ($i = 1、2、3 \dots n$) 建立原假设 H0 和备择假设 H1。

$$H_0: \beta_{1k} = \beta_{2k} = \dots = \beta_{nk};$$
$$H_1: \beta_{ik}(i = 1、2、3 \dots n) \text{并不完全相等};$$

以 $F_2(k)$ 为检验统计量，其分布近似为分子自由度为 γ_1^2/γ_2 ，分母自由度为 δ_1^2/δ_2 的 F 分布。对于显著性水平 α ,如果 $F_2(k) \geq F_\alpha(\gamma_1^2/\gamma_2, \delta_1^2/\delta_2)$,否定 H0;否则接受 H0。

$$F_2(k) = \frac{\frac{V_k^2}{\gamma_1}}{\hat{\sigma}^2}$$

(4)

式中 $V_k^2 = \frac{1}{n} \sum_{i=1}^n (\widehat{\beta}_{ik} - \frac{1}{n} \sum_{i=1}^n \widehat{\beta}_{ik})^2$; $\gamma_i = tr \left[\frac{1}{n} B^T \left(I - \frac{1}{n} J \right) B \right]^i$ ($i = 1,2$); $\hat{\sigma}^2 = \frac{RSS_G}{\delta^1}$;关于检验统计量 $F_2(k)$ 的构建理论和过程的详细信息，请参见(Leung 等, 2000)。

2.4.5 模型评价 本研究计算了随机交叉验证和空间交叉验证两种情况下的方根误差系数（Root-mean-square error, RMSE）、决定系数(R-Squared, R2)，将它们作为模型的评价指标。

2.4.6 AGB 的空间制图及其不确定性

本研究采用自举法得到 AGB 的平均预测图和不确定性。具体来说，整个数据集以 9:1 的比例分为训练集和测试集。使用训练集建立模型，并用于预测整个研究区域的 AGB。此过程重复 100 次，得到 100 张 AGB 预测图。计算这 100 张预测图的平均值，作为最终的平均预测结果。同时，利用这 100 个预测图计算不确定性，不确定性的计算表达式(Wu 等, 2023):

$$Uncertainty = \frac{B_{95\%} - B_{5\%}}{B_{mean}}$$

(5)

其中 $B_{95\%}$ 和 $B_{5\%}$ 分别表示 100 次预测值的 95%置信区间和 5%置信区间的上界和下界， B_{mean} 表示 100 张图的预测平均值。

3 结果与分析

3.1 AGB 最优 测因子

我们根据 2.4.1 中描述的策略提取全局和局部最优特征。提取局部最优特征的分区方法，以及子区域

内 AGB 和样本数量的信息，如表 4 所示。全局和局部最优特征得提取结果如表 5 所示，提取结果大致分为单波段、植被指数和环境属性三类。

对于单波段特征，本研究成功捕获了 B3(绿色波段)、B4(红色波段)和 B12(短波红外波段)等能够反映植被光谱特点的重要特征(Q. Zhang 等, 2006; P. Li 等, 2023)，但是忽略了关键的 B8(近红外波段)。B8 不仅是最直接表达冠层水平的叶片光学特性(Asner, 1998)的波段，而且与多种植被指数的构建密切相关，如 MSR、NDWI2 和 RDVI；在植被指数方面，被广泛使用的 NDVI 在使用整体数据集进行特征提取时并没有被提取，而是在局部区域提取时被识别的；在环境属性方面，SDP 和 AMT 等在植物生长中起关键作用的特征仅在特定的局部区域与 AGB 有显著关系。

这些结果表明，在全球或局部水平上，特征提取结果存在差异。在环境异质性较强的地区，使用所有数据提取的最优特征可能不够充分和准确，在局部小范围内对模型贡献较大或更重要且常用的指标可能会丢失。因此，需要将全局和局部的提取结果结合起来，提高生物量预测模型的预测精度。

表 4. 不同子区域内 AGB 的详细信息

Tab. 4 General information of the AGB in different zone						
分区方法	子区域	生物量	胸径	树高	基底面积	样本点
Partition basis	subzone	Mean AGB (t/ha)	Mean D BH(cm)	Mean hei ght(m)	Mean base area (m2/0.1ha)	Sample size
森林类型	落叶阔叶	78.91	13.313	11.066	1.936	201
	落叶针叶	89.43	15.339	12.400	2.174	104
植被区划	寒温带针叶林	89.57	14.170	11.879	2.138	199
	温带草原	77.14	14.807	11.777	1.925	76
	温带草原和温带沙漠的混合地带	53.19	11.293	8.889	1.514	35
气候带(Peel 等, 2007)	干旱, 草原, 寒冷	57.51	11.860	9.330	1.597	20
	干旱, 沙漠, 寒冷	57.66	11.127	9.108	1.644	9
	寒冷, 冬季干燥, 夏季炎热	67.85	13.460	10.829	1.767	43
	寒冷, 冬季干燥, 夏季较热	78.79	13.811	11.230	1.995	27
	寒冷, 冬季干燥, 夏季较冷	89.55	14.477	12.022	2.129	206
土壤类型	半淋溶土	91.55	14.356	11.924	2.164	60
	半水成土	80.62	13.788	11.548	1.993	53
	初育土	63.34	13.681	10.513	1.634	26
	钙层土	72.82	13.761	10.913	1.831	42
	干旱土	58.59	10.943	8.267	1.658	7
	淋溶土	93.89	14.116	11.837	2.254	44
	水成土	84.63	14.426	12.032	2.053	72

表 5. 从 85 个变 中提取出的最优特征

Tab. 5 The optimal feature extracted from 85 predictor variables.		
来源	全局最优特征	局部最优特征
单波段	B3, B4, B12	B1, B5, B6, B8, B11
植被指数	RDVI, CARI, PRI, MSR NDWI2, TGS I	NDVI, TNDVI, NDWI1, MDI2, SR, MDI1, REP, MSI, NDVIrel, MSAVI, SIPI, NDCI, NVI, MTCl, Clgreen
环境属性	GSP	AMT, SDP

3.2 空 平稳性分析

本研究对 AGB 预测因子及其驱动因子进行空间非平稳性检验，检验结果如表 6、表 7 所示。有 14 个

AGB 预测特征的 p 值低于 0.05，表明这些变量的 GWR 回归系数存在显著的空间差异。这些变量中有三点值得注意：首先，无论是全局还是局部提取的结果，最优特征均存在空间非平稳性问题。例如，在 10 个全局最优特征中，有 5 个特征的 p 值小于 0.05，如 B3、B4、CARI、MSR 和 GSP。在局部提取中，我们发现 9 个特征与 AGB 的关系不稳定。其次，虽然 NDVI 属于局部而非全局最优集，但其回归系数不存在显著的空间差异，这意味着 NDVI 仍然可以稳定地描述所有研究区域的 AGB 分布。第三，无论是光谱特征还是环境特征，其与 AGB 的关系都可能发生变化。表 7 的结果表明，在 8 个 AGB 驱动因素中有 4 个因素表现出显著的空间非平稳性。

表 6. AGB 测因子的 F2 显著性检 结果							
Tab. 6 Results of the F2 significance test for AGB predictors.							
特征类型	预测因	F2	P-value	特征	预测因子	F2	P-value
	子			类型			
全局最优	B3	2.730	0.000	局部最优	TNDVI	1.015	0.441
	B4	1.939	0.000		NDWI1	0.826	0.819
	B12	0.165	1.000		MDI2	2.701	0.000
	RDVI	0.435	0.999		SR	1.860	0.000
	CARI	1.730	0.001		MDI1	1.556	0.003
	PRI	0.181	1.000		REP	0.112	1.000
	MSR	1.820	0.000		MSI	1.088	0.313
	NDWI2	0.203	1.000		NDVIre1	0.684	0.961
	TGSI	0.332	0.999		MSAVI	1.804	0.000
	GSP	3.437	0.000		SIPI	3.087	0.000
局部最优	B1	3.547	0.000		NDCI	3.564	0.000
	B5	1.028	0.416		NVI	0.258	1.000
	B6	1.869	0.000		MTCI	0.765	0.920
	B8	0.883	0.680		CIgreen	1.277	0.061
	B11	0.110	1.000		SDP	0.874	0.752
	NDVI	0.828	0.845		AMT	4.444	0.000

表 7. AGB 动因子的 F2 显著性检 结果					
Tab. 7 Results of the F2 significance test for AGB driving factors.					
驱动因子	F2	P-value	驱动因子	F2	P-value
Ele	0.687	0.975	GSP	14.672	0.000
Slope	1.771	0.000	SDP	1.821	0.000
Aspect	0.442	0.999	ShD	1.177	0.189
AMT	1.221	0.091	HCI	16.552	0.000

3.3 模型评价与比较

表 8 总结了每个模型在测试数据集上的性能，评估指标包括 RMSE 和 R^2 。无论是随机交叉验证还是空间交叉验证，GRF 的精度是最高的， R^2 分别达到 0.622 和 0.481。GRF 不仅克服了传统机器学习的缺点，在评估制图结果方面也有自己独特的优势。(Meyer & Pebesma, 2022)指出，机器学习的制图结果通常使用 RMSE 或 R^2 等指标进行结果可靠性的量化，然而这种单值的指标平均了研究范围内的所有预测误差，掩盖了不同空间区域间估计误差的差异。GRF 可以同时评估多个局部 RF 模型，从而获得不同区域之间评估精度的差异(图 3)。

表 8. 四种模型 机交叉 证和空 交叉 证下测试 的表现				
Tab. 8 Performances of four models on the validation data using random CV and spatial CV.				
Model	random CV		Spatial CV	
	RMSE	R2	RMSE	R2

RF	22.05	0.599	24.77	0.487
GBR	23.30	0.552	25.889	0.439
SVR	30.832	0.216	31.314	0.180
GRF	21.397	0.622	24.90	0.481




图 3 GRF 的 (a) 均方根误差和决定系数(b)的空间分布

Fig. 3 Local (a) Root-mean-square error (RMSE) and (b) Coefficient of determination (R-Squared, R^2) for GRF.

3.4 AGB 的空 分布和不确定性制图

图 4 显示了四种模型的 AGB 的全局和局部空间分布图。内蒙古的 AGB 主要分布在东北和中部地区，西部地区仅有零星分布。四种模型估算的 AGB 皆主要集中在 0~138Mg/ha 左右，但是 GBR 和 SVR 的估算结果出现明显的条带效应。RF、GBR 和 SVR 在整个东部地区对 AGB 的估算较高，而 GRF 则在东北角 A GB 较低，随之向南部的延长，AGB 逐渐增大。我们发现 GRF 表现的趋势与(Y. Chen 等, 2023)和(Yang 等, 2023)的研究结果是一致的。三种机器学习方法之所以没能描述出 AGB 东部地区的趋势变化，可能是因为他们属于全局模型，对于局部细节的描述不够充分，造成整个区域估算偏高的现象。图 5 是四个模型的不确定性图，可以看出 GRF 模型的不确定性在四个模型中是最低的。




图 4 (A)地理随机森林、(B)随机森林、(C)梯度增强回归、(D)支持向量回归的全局和局部预测图
Fig. 4 The global and local prediction maps of (A) Geographically Random Forest (GRF), (B) Random Forest (RF), (C) Gradient Boosting Regressor (GBR), (D) Support Vector Regression (SVR).




图 5 (a)地理随机森林、(b)随机森林、(c)梯度增强回归、(d)支持向量回归的不确定性图
Fig. 5 Uncertainty map of (a) Geographically Random Forest (GRF), (b) Random Forest (RF), (c) Gradient Boosting Regressor (GBR), (d) Support Vector Regression (SVR).

3.5 AGB 动因素分析

对研究区域的八个驱动因素的影响力进行了分析,结果如图 6 所示。HCI 的影响最大, GSP 次之, aspect 的影响最弱。此外,对四个存在空间非平稳性的驱动因子的影响力进行了空间量化(图 7)。我们发现随着海拔的升高,坡度的影响力从东向西逐渐增强。GSP 因子的驱动力从东到西呈明显的梯度递减。SDP 因子从东到西出现了影响力的下降,但变化幅度较小。HCI 因子的影响没有明显的梯度变化,在整个研究区的影响力较强,仅在一些小区域出现减弱。




图 6 每种预测因子在整个研究区域内的影响力

Fig. 6 The influence of each driver in the whole study area




图 7 (a)Slope, (b)GSP, (c) SDP 和 (d) HCI 驱动力的空间分布

Fig. 7 The spatial distribution of the driving force of (a) Slope, (b)GSP, (c) SDP, (d) HCI.

4 讨论

4.1 空间非平稳性

在光谱特征方面,单波段和植被指数均表现出明显的空间非平稳性。(Foody等, 2003)发现不同位置的回归模型, Landsat的同一种单波段或植被指数与AGB之间的回归系数是不同的。这种空间非平稳性与

植被与电磁波间的交互模式有关。AGB直接由木材体积和叶片碳含量特征决定,这些特征会影响光谱反射模式(Rawat等, 2019),从而能够将AGB变化映射到光谱特征的差异上。然而,除了与AGB相关的性状外,光谱反射率模式还可以受到其他性状的影响,如叶面积指数、树间性状、树种等(Asner, 1998; Rautia inen等, 2004; Hovi等, 2017)等等。例如,(Wallis等, 2023)观察到高光谱反射率与森林碳含量之间的联系明显受到树种成分的影响。忽略这些额外性状的影响,直接拟合AGB与特定谱特征之间的函数关系,将导致函数的系数估计不准确。尽管许多研究尝试纳入了更多的光谱变量或激光雷达结构变量来消除这些额外的特征的影响,但有限的变量集可能无法全面描绘众多植被性状(Ollinger, 2011),从而导致空间非平稳性问题仍然存在。例如(Yang等, 2022)发现,将光谱信息与LiDAR数据相结合可以提高估算精度,但模型性能在不同的森林类型间仍存在差异。

内蒙古森林生态系统的生物特征(树种和年龄)、人为影响(天然林或人工林)和地理环境(气候、海拔)从东到西发生显著变化(Lee等, 2023, 2024),这种变化可能会改变AGB与环境特征之间的响应关系,例如本研究中发现存在显著空间非平稳性的AMT和GSP 这两个环境因子(Carnicer等, 2013)。对于AMT因子,(Y. Liu等, 2014)发现在北方针叶林、温带海洋林、亚热带湿润林和热带干燥林中,AGB与AMT呈线性正相关,而在北方山地系统、温带山地系统和亚热带山地系统中,AGB与AMT呈非线性关系。(X. Chen等, 2023)发现AMT对常绿针叶林中AGB初始积累速率有显著的正向影响,而对阔叶落叶林中则有抑制作用,对两种林型AGB饱和值的影响存在差异。对于GSP因子,GSP代表的是生长季的总降水量,是树木AGB积累的主要限制因子(Liang等, 2023; Oksanen, 2021)。然而这种限制的强度因树种而异,有的树种可能抗旱性强,有的树种可能抗旱性弱(Z. Liu等, 2022; Yuan等, 2022)。例如,(H. Zhang等, 2015)发现不同森林类型的AGB对GSP变量的敏感性存在差异。(Wang等, 2006)注意到不同树种相对基底面积和GSP的响应曲线不一致。

4.2 GRF 模型的优势分析

许多研究发现,将地理加权法则与机器学习的非线性拟合能力相结合,可以优于传统的机器学习或地理加权模型。例如,(T. Li等, 2020)将神经网络与GWR结合,提出了地理和时间加权神经网络(Geographically and Temporally Weighted Regression, GTWNN)模型,发现新模型的精度超过了GWR模型。同样,(Feng等, 2021)发现GTWNN模型在农作物产量预测方面优于人工神经网络、地理和时间加权回归模型和支持向量回归。(Xu等, 2021)引入了一种多因素地理加权机器学习方法,在地表温度的空间降尺度方面显示出显著优势。(Quiñones等, 2021)发现,与传统的局部和全局模型相比,使用地理加权随机森林调查疾病流行的风险因素显示出更大的潜力。在本研究中,我们采用GRF方法,将RF强大的拟合能力与GWR的空间非平稳性分析能力相结合,提高大范围区域及其局部小区域AGB的制图精度,降低了不确定性。

4.3 AGB驱动因子及其相对应的森林管理措施

坡度在相对较小的空间范围内会改变温度、日照条件以及季节气候周期,从而对AGB产生一定的影响(Nie等, 2019)。然而,坡度与AGB间的影响关系在不同的地理区域有所不同。(Shen等, 2018)研究发现,坡度对AGB的影响在盆地、山区和沿海地区差异明显。在本研究中,我们发现坡度对东部地区AGB的影响相对较小,但在中西部地区影响力逐渐增加。这可能是因为东部地区海拔较低,坡度引起的温度和日照条件变化很小;但中西部地区平均海拔较高,坡度带来的海拔变化,更容易引起AGB积累的环境条件突变,从而增强其对AGB的影响。

GSP表示生长季节的总降水量。本研究发现,其影响力在东部地区最大,而在中部温带草原和西部温带荒漠地区则出现急剧下降。中西部地区是干旱缺水地带,树木的生长往往采用人工灌溉,人为因素的干扰使得该区域的GSP因子对AGB的影响力较小。然而,东北部原始林区域的夏季降水丰沛,且人为干预较小,使得GSP能够直接影响树木生长,对AGB的驱动力在整个区域内达到最高。

SDP强调生长季内月降水量的稳定性和均匀性,如果SDP过高,月降水量剧烈波动,可能会导致树木

在短时间内浸水或缺水。水分过多会导致根系缺氧，而水分不足会导致干旱胁迫，两者都会抑制树木的生长。本研究发现，SDP在中西部地区的重要性较低，这可能是由于该区域较为干旱，土壤具有较强的吸水能力，短时强降雨事件未使树木处于根系缺氧状态。而在土壤含水量较高的东北地区，局部强降雨更易引起土壤表面淹水，树木根系淹没，使得树木大面积死亡，因此SDP对该地区AGB积累的影响较大。

HCI代表物种多样性，本研究发现在8个因素中，HCI的驱动力最强，这与许多研究的结果一致(Con等, 2013; Y. Zhang等, 2017)，影响力在整个研究区域内比较均匀，没有明显的梯度变化。

综上所述，同一驱动因素对不同地理区域AGB的驱动力存在差异，这是区域环境条件、地形特征和人为因素综合作用的结果。因此，我们需要制定适应特定环境及生态条件的森林管理措施，更有效地改善森林生态系统的健康和生产力。例如，在内蒙古的西部地区，由于坡度变化对AGB的影响较大，应优先选择坡度较低的区域进行植树。在东北地区，坡度的影响相对较小，但应特别注意极端降水事件对AGB的影响，并加强对低洼易涝地区的监测，防止树木因过度涝渍而死亡。此外，HCI作为影响AGB的最强驱动因子，在所有区域都表现出较高的影响力，建议在所有区域避免单一树种种植，优先考虑多物种混合种植，以提高生态系统的稳定性和适应性。

5 结论

本研究利用 GRF 建立 AGB 预测模型，成功克服了预测变量与 AGB 之间的空间非平稳性，实现了更高的 AGB 估计精度，证明了该方法比传统机器学习方法具有更好的性能。同时，本研究还利用 GRF 模型建立 AGB 驱动模型，分析 AGB 驱动力的空间变异，从而更好地指导管理者在相对较小的范围内制定精准政策。

参 考 文 献

- 吴善玉, 鲍艳松, 李叶飞, & 吴莹. (2021). 基于神经网络算法的 Sentinel-1 和 Sentinel-2 遥感数据联合反演土壤湿度研究. *大气科学学报*, 44(4), 636 - 644.
- 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., ... Lucas, R. (2022). A comprehensive framework for assessing the accuracy and uncertainty of global above-ground biomass maps. *Remote Sensing of Environment*, 272, 112917.
- Asner, G. P. (1998). Biophysical and Biochemical Sources of Variability in Canopy Reflectance. *Remote Sensing of Environment*, 64(3), 234 - 253.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24 - 31.
- Carnicer, J., Brbeta, A., Sperlich, D., Coll, M., & Penuelas, J. (2013). Contrasting trait syndromes in angiosperms and conifers are associated with different responses of tree growth to temperature on a large scale. *FRONTIERS IN PLANT SCIENCE*, 4, 409.
- Chen, X., Luo, M., & Larjavaara, M. (2023). Effects of climate and plant functional types on forest above-ground biomass accumulation. *Carbon Balance and Management*, 18(1), 5.
- Chen, Y., Feng, X., Fu, B., Ma, H., Zohner, C. M., Crowther, T. W., Huang, Y., Wu, X., & Wei, F. (2023). Maps with 1km resolution reveal increases in above- and belowground forest biomass carbon pools in China over the past 20 years. *Earth System Science Data*, 15(2), 897 - 910.
- Con, T. V., Thang, N. T., Ha, D. T. T., Khiem, C. C., Quy, T. H., Lam, V. T., Van Do, T., & Sato, T. (2013). Relationship between aboveground biomass and measures of structure and species diversity in tropical forests of Vietnam. *Forest Ecology and Management*, 310, 213 - 218.

- Erb, K.-H., Kastner, T., Plutzer, C., Bais, A. L. S., Carvalhais, N., Fetzel, T., Gingrich, S., Haberl, H., Lauk, C., Niedertscheider, M., Pongratz, J., Thurner, M., & Luyssaert, S. (2018). Unexpectedly large impact of forest management and grazing on global vegetation biomass. *Nature*, 553(7686), 73–76.
- Fahey, T. J., Woodbury, P. B., Battles, J. J., Goodale, C. L., Hamburg, S. P., Ollinger, S. V., & Woodall, C. W. (2010). Forest carbon storage: Ecology, management, and policy. *Frontiers in Ecology and the Environment*, 8(5), 245–252.
- Fassnacht, F. E., Hartig, F., Latifi, H., Berger, C., Hernández, J., Corvalán, P., & Koch, B. (2014). Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment*, 154, 102–114.
- Feng, L., Wang, Y., Zhang, Z., & Du, Q. (2021). Geographically and temporally weighted neural network for winter wheat yield prediction. *Remote Sensing of Environment*, 262, 112514.
- Finley, A. O. (2011). Comparing spatially-varying coefficients models for analysis of ecological data with non-stationary and anisotropic residual dependence. *Methods in Ecology and Evolution*, 2(2), 143–154.
- Foody, G. M., Boyd, D. S., & Cutler, M. E. J. (2003). Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment*, 85(4), 463–474.
- Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189–1232.
- Georganos, S., Grippa, T., Niang Gadiaga, A., Linard, C., Lennert, M., Vanhuyse, S., Mboga, N., Wolff, E., & Kalogirou, S. (2021). Geographical random forests: A spatial extension of the random forest algorithm to address spatial heterogeneity in remote sensing and population modelling. *Geocarto International*, 36(2), 121–136.
- Georganos, S., & Kalogirou, S. (2022). A Forest of Forests: A Spatially Weighted and Computationally Efficient Formulation of Geographical Random Forests. *ISPRS International Journal of Geo-Information*, 11(9), Article 9.
- Gu, Y., Liu, D., Arvin, R., Khattak, A. J., & Han, L. D. (2023). Predicting intersection crash frequency using connected vehicle data: A framework for geographical random forest. *Accident Analysis & Prevention*, 179, 106880.
- Hovi, A., Raitio, P., & Rautiainen, M. (2017). A spectral analysis of 25 boreal tree species. *Silva Fennica*, 51(4).
- Ifo, S. A., Moutsambote, J.-M., Koubouana, F., Yoka, J., Ndai, S. F., Bouetou-Kadilamio, L. N. O., Mampouya, H., Jourdain, C., Bocko, Y., Mantota, A. B., Mbemba, M., Mouanga-Sokath, D., Odende, R., Mondzali, L. R., Wenina, Y. E. M., Ouissika, B. C., & Joel, L. J. (2016). Tree Species Diversity, Richness, and Similarity in Intact and Degraded Forest in the Tropical Rainforest of the Congo Basin: Case of the Forest of Likouala in the Republic of Congo. *International Journal of Forestry Research*, 2016, e7593681.
- Jin, Y., Liu, C., Qian, S. S., Luo, Y., Zhou, R., Tang, J., & Bao, W. (2022). Large-scale patterns of understory biomass and its allocation across China's forests. *Science of The Total Environment*, 804, 150169.
- Lee, Y.-J., Lee, C.-B., & Lee, M.-K. (2023). Tree size variation induced by stand age mainly regulates aboveground biomass across three major stands of temperate forests in South Korea. *Frontiers in Forests and Global Change*, 6.
- Lee, Y.-J., Lee, H.-I., Lee, C.-B., Lee, K.-H., Kim, R.-H., & Ali, A. (2024). Abiotic and stand age-induced changes in tree diversity and size inequality regulate aboveground biomass and soil organic carbon stock in temperate forests of South Korea. *CATENA*, 237, 107827.
- Leung, Y., Mei, C.-L., & Zhang, W.-X. (2000). Statistical Tests for Spatial Nonstationarity Based on the Geographically Weighted Regression Model. *Environment and Planning A: Economy and Space*, 32(1), 9–32.
- Li, P., Huang, X., Yin, S., Bao, Y., Bao, G., Tong, S., Dashzeveg, G., Nanzad, T., Dorjsuren, A., Enkhnasan, D., & Ariunaa, M. (2023). Optimizing spectral index to estimate the relative chlorophyll content of the

- forest under the damage of *Erannis jacobsoni* Djak in Mongolia. *Ecological Indicators*, 154, 110714.
- Li, T., Shen, H., Yuan, Q., & Zhang, L. (2020). Geographically and temporally weighted neural networks for satellite-based mapping of ground-level PM_{2.5}. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 178–188.
- Liang, M., Han, T., Ma, J., Li, R., Yang, Y., Qiu, X., Sun, H., & Zheng, H. (2023). Response of temperate forest ecosystem services to rainfall: A case study in the forest nature reserves of northern China. *Frontiers in Ecology and Evolution*, 11.
- Liu, Y., Yu, G., Wang, Q., & Zhang, Y. (2014). How temperature, precipitation and stand age control the biomass carbon density of global mature forests. *Global Ecology and Biogeography*, 23(3), 323–333.
- Liu, Z., Ye, L., Wei, Z., Jiang, J., Zhang, Q., & Lv, X. (2022). Water use by trees is linked to precipitation: A case study of a mixed forest in a hilly area in southern China. *Ecological Indicators*, 143, 109343.
- Luo, Y., Wang, X., Ouyang, Z., Lu, F., Feng, L., & Tao, J. (2019). ChinAllomeTree 1.0: China's normalized tree biomass equation dataset. *Earth System Science Data Discussions*, 1–75.
- Ma, H., Mo, L., Crowther, T. W., Maynard, D. S., van den Hoogen, J., Stocker, B. D., Terrer, C., & Zohner, C. M. (2021). The global distribution and environmental drivers of aboveground versus belowground plant biomass. *Nature Ecology & Evolution*, 5(8), Article 8.
- Meyer, H., & Pebesma, E. (2022). Machine learning-based global maps of ecological variables and the challenge of assessing them. *Nature Communications*, 13(1), Article 1.
- Muro, J., Linstaedter, A., Magdon, P., Woellauer, S., Maenner, F. A., Schwarz, L.-M., Ghazaryan, G., Schultz, J., Malenovsky, Z., & Dubovyk, O. (2022). Predicting plant biomass and species richness in temperate grasslands across regions, time, and land management with remote sensing and deep learning. *Remote Sensing of Environment*, 282, 113262.
- Nie, X., Guo, W., Huang, B., Zhuo, M., Li, D., Li, Z., & Yuan, Z. (2019). Effects of soil properties, topography and landform on the understory biomass of a pine forest in a subtropical hilly region. *CATENA*, 176, 104–111.
- Oksanen, E. (2021). Birch as a Model Species for the Acclimation and Adaptation of Northern Forest Ecosystem to Changing Environment. *Frontiers in Forests and Global Change*, 4.
- Ollinger, S. V. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375–394.
- Pan, Y., Birdsey, R. A., Phillips, O. L., & Jackson, R. B. (2013). The Structure, Distribution, and Biomass of the World's Forests. *Annual Review of Ecology, Evolution, and Systematics*, 44(1), 593–622.
- Peel, M. C., Finlayson, B. L., & McMahon, T. A. (2007). Updated world map of the Köppen-Geiger climate classification. *Hydrology and Earth System Sciences*, 11(5), 1633–1644.
- Propastin, P. A. (2009). Spatial non-stationarity and scale-dependency of prediction accuracy in the remote estimation of LAI over a tropical rainforest in Sulawesi, Indonesia. *Remote Sensing of Environment*, 113(10), 2234–2242.
- Quiñones, S., Goyal, A., & Ahmed, Z. U. (2021). Geographically weighted machine learning model for untangling spatial heterogeneity of type 2 diabetes mellitus (T2D) prevalence in the USA. *Scientific Reports*, 11(1), Article 1.
- Rautiainen, M., Stenberg, P., Nilson, T., & Kuusk, A. (2004). The effect of crown shape on the reflectance of coniferous stands. *Remote Sensing of Environment*, 89(1), 41–52.
- Rawat, M., Arunachalam, K., Arunachalam, A., Alatalo, J., & Pandey, R. (2019). Associations of plant functional diversity with carbon accumulation in a temperate forest ecosystem in the Indian Himalayas. *Ecological Indicators*, 98, 861–868.
- Shen, A., Wu, C., Jiang, B., Deng, J., Yuan, W., Wang, K., He, S., Zhu, E., Lin, Y., & Wu, C. (2018). Spatiotemporal Variations of Aboveground Biomass under Different Terrain Conditions. *Forests*, 9(12), Article 12.

- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199 – 222.
- Song, Y., Wang, J., Ge, Y., & Xu, C. (2020). An optimal parameters-based geographical detector model enhances geographic characteristics of explanatory variables for spatial heterogeneity analysis: Cases with different types of spatial data. *GIScience & Remote Sensing*, 57(5), 593 – 610.
- Stewart Fotheringham, A., Charlton, M., & Brunsdon, C. (1996). The geography of parameter space: An investigation of spatial non-stationarity. *International journal of geographical information systems*, 10(5), 605 – 627.
- Wallis, C. I. B., Crofts, A. L., Inamdar, D., Arroyo-Mora, J. P., Kalacska, M., Laliberté, É., & Vellend, M. (2023). Remotely sensed carbon content: The role of tree composition and tree diversity. *Remote Sensing of Environment*, 284, 113333.
- Wang, X.-P., Tang, Z.-Y., & Fang, J.-Y. (2006). Climatic Control on Forests and Tree Species Distribution in the Forest Region of Northeast China. *Journal of Integrative Plant Biology*, 48(7), 778 – 789.
- Wu, Z., Chen, Y., Yang, Z., Liu, Y., Zhu, Y., Tong, Z., & An, R. (2023). Spatial distribution of lead concentration in peri-urban soil: Threshold and interaction effects of environmental variables. *Geoderma*, 429, 116193.
- Xu, S., Zhao, Q., Yin, K., He, G., Zhang, Z., Wang, G., Wen, M., & Zhang, N. (2021). Spatial Downscaling of Land Surface Temperature Based on a Multi-Factor Geographically Weighted Machine Learning Model. *Remote Sensing*, 13(6), Article 6.
- Yang, Q., Niu, C., Liu, X., Feng, Y., Ma, Q., Wang, X., Tang, H., & Guo, Q. (2023). Mapping high-resolution forest aboveground biomass of China using multisource remote sensing data. *GIScience & Remote Sensing*, 60(1), 2203303.
- Yang, Q., Su, Y., Hu, T., Jin, S., Liu, X., Niu, C., Liu, Z., Kelly, M., Wei, J., & Guo, Q. (2022). Allometry-based estimation of forest aboveground biomass combining LiDAR canopy height attributes and optical spectral indexes. *Forest Ecosystems*, 9, 100059.
- Yuan, J., Yan, Q., Wang, J., Xie, J., & Li, R. (2022). Different responses of growth and physiology to warming and reduced precipitation of two co-existing seedlings in a temperate secondary forest. *Frontiers in Plant Science*, 13.
- Zhang, H., Song, T., Wang, K., Wang, G., Liao, J., Xu, G., & Zeng, F. (2015). Biogeographical patterns of forest biomass allocation vary by climate, soil and forest characteristics in China. *Environmental Research Letters*, 10(4), 044014.
- Zhang, Q., Xiao, X., Braswell, B., Linder, E., Ollinger, S., Smith, M.-L., Jenkins, J. P., Baret, F., Richardson, A. D., Moore, B., & Minocha, R. (2006). Characterization of seasonal variation of forest canopy in a temperate deciduous broadleaf forest, using daily MODIS data. *Remote Sensing of Environment*, 105(3), 189 – 203.
- Zhang, Y., Chen, H. Y. H., & Taylor, A. R. (2017). Positive species diversity and above-ground biomass relationships are ubiquitous across forest strata despite interference from overstorey trees. *Functional Ecology*, 31(2), 419 – 426.