

doi:10.11733/j.issn.1007-0435.2026.02.018

引用格式:马磊超,王兴,杨秀春,等.基于无人机多源遥感数据的灌丛草原地上生物量估算[J].草地学报,2026,34(2):559—572

MA Lei-chao, WANG Xing, YANG Xiu-chun, et al. Aboveground Biomass Estimation in Shrub-Encroached Grasslands by Using Multi-Source UAV Remote Sensing[J]. Acta Agrestia Sinica, 2026, 34(2):559—572

基于无人机多源遥感数据的灌丛草原地上生物量估算

马磊超^{1,2}, 王兴¹, 杨秀春^{1*}, 杨东¹, 王子超¹, 邢晓语¹

(1. 北京林业大学草业与草原学院, 北京 100083; 2. 中国地质调查局自然资源综合调查指挥中心, 北京 100055)

摘要:气候变化与人类活动加剧了全球草原灌丛化,严重威胁草原生态系统健康,亟需高效精准的生物量监测技术。本研究以锡林郭勒盟灌丛草原为研究区,基于无人机激光雷达(LiDAR)和高光谱数据,结合地面实测数据,采用逐步多元线性回归、支持向量机和随机森林等方法探究了灌丛草原地上生物量(Above-ground biomass, AGB)的最佳反演模型。结果表明,基于LiDAR数据计算的草层平均高度、高光谱数据的红边区间反射率与AGB显著相关。高光谱在草本AGB反演中优于LiDAR精度($R^2=0.87$ vs. 0.24),而LiDAR较高光谱则更适用于灌木AGB反演($R^2=0.58$ vs. 0.47)。数据融合能显著提升模型精度,LiDAR和高光谱数据多源特征融合的随机森林模型使草本和灌木AGB的 R^2 分别达到0.88和0.64。相关成果可为灌丛草原可持续利用和精细化管理提供重要科学支撑。

关键词:草原地上生物量;激光雷达;高光谱;机器学习;灌丛草原

中图分类号:S812

文献标识码:A

文章编号:1007-0435(2026)02-0559-14

Aboveground Biomass Estimation in Shrub-Encroached Grasslands by Using Multi-Source UAV Remote Sensing

MA Lei-chao^{1,2}, WANG Xing¹, YANG Xiu-chun^{1*}, YANG Dong¹, WANG Zi-chao¹, XING Xiao-yu¹

(1. School of Grassland Science, Beijing Forestry University, Beijing 100083, China; 2. Command Center for Natural Resources Comprehensive Survey, China Geological Survey, Beijing 100055, China)

Abstract: Shrub encroachment in grasslands, intensified by climate change and anthropogenic activities, represents a substantial threat to the health of grassland ecosystems. This underscores the pressing need for effective and precise biomass monitoring methodologies. The present study was carried out in the shrub-encroached grasslands of the Xilingol League, to investigate optimal above ground biomass (AGB) estimation model by utilizing unmanned aerial vehicle-based LiDAR and hyperspectral data validated against field measurements. Step-wise multiple linear regression, support vector machine, and random forest algorithms were employed for analysis. The results demonstrated a robust correlation between AGB and both LiDAR-derived mean canopy height and hyperspectral reflectance within the red-edge spectral region. Hyperspectral data demonstrated superior accuracy to LiDAR for herbaceous AGB inversion ($R^2=0.87$ vs. 0.24), whereas LiDAR performed better than hyperspectral data for shrub AGB inversion ($R^2=0.58$ vs. 0.47). Data fusion significantly improved the model performance, with the random forest model integrating features from both LiDAR and hyperspectral data achieving R^2 values of 0.88 and 0.64 for herbaceous and shrub AGB, respectively. The related findings offer critical scientific support for the sustainable utilization and precise management of shrub-encroached grasslands.

Key words: Grassland above-ground biomass; LiDAR; Hyperspectral; Machine learning; Shrub-encroached grassland

收稿日期:2025-03-28;修回日期:2025-05-16

基金项目:国家自然科学基金项目(41571105)资助

作者简介:马磊超(1981-),男,汉族,河南沈丘人,硕士研究生,主要从事草原遥感研究, E-mail: leichaoma@126.com; *通信作者 Author for correspondence, E-mail: yangxiuchun@bjfu.edu.cn

草原作为我国重要的陆地生态系统,发挥着涵养水源、防风固沙、固碳释氧等关键生态功能^[1-3]。然而,气候变化与人类活动加剧了草原灌木化的风险,迫切需要高效、精准的技术手段监测灌木地上生物量(Above-ground biomass, AGB)。传统地面调查方法效率低、覆盖范围有限,难以满足大尺度、高频次的监测需求。无人机遥感技术以其高时空分辨率、低成本和灵活性,为草原生物量监测提供了新的解决方案^[4-6]。特别是在锡林郭勒盟等灌木草原地区,草本与灌木共生的复杂结构使得生物量估算更具挑战性。融合光学传感器与激光雷达数据(LiDAR)的无人机遥感技术,有望显著提高监测精度,为草原生态管理提供科学依据。

草原植被 AGB 是反映了净初级生产力(Net primary productivity, NPP)的重要指标^[1]。传统的刈割称重法虽然精度较高,但成本高、效率低且具有破坏性,无法满足大范围研究的需求。遥感技术的发展为草原生物量估算提供了有效途径。目前常用的遥感反演方法包括统计模型、物理模型和机器学习方法。统计模型(如基于 NDVI、SAVI 等植被指数的回归模型)虽然应用广泛,但其精度易受环境因素和模型假设的限制^[7]。基于辐射传输理论的物理模型(如 PROSAIL)可通过叶面积指数(LAI)间接估算生物量,但参数设置复杂,限制了其实际应用^[8]。机器学习方法(如随机森林、支持向量机和 BP 神经网络)具有强大的非线性建模能力,在生物量估算中表现出较高的精度和稳定性^[9-10]。然而,草地类型的异质性,特别是灌木草原和典型草原的灌木化趋势,对估算方法的适用性提出了挑战^[11]。因此,如何准确估算不同类型草地的生物量,并评估不同方法的适用性,是当前草地生态研究的关键问题。

近年来,多源遥感数据融合在 AGB 反演中取得了显著进展。LiDAR 凭借其提供高精度三维结构信息的能力,在森林和高大灌木生物量估算中表现突出^[12-13]。但对于低矮灌木和高大草本植被,单一 LiDAR 数据因植被密集和光谱信息匮乏而存在局限。光学遥感,特别是中低分辨率卫星数据(如 MODIS、Landsat、Sentinel-2),在大尺度草地生物量估算中发挥了重要作用^[14-17],但传统多光谱数据受限于波段宽度,难以提供精细的光谱信息。高光谱遥感以其连续光谱的优势,显著提升了生物量反演精度^[18-20]。无人机搭载高光谱传感器在草地生态研

究中的应用日益增多,相比手持光谱仪,具有更高的空间覆盖范围和数据获取效率。未来, LiDAR 与高光谱数据、光学数据与气候数据的融合,并结合机器学习方法,将是提高生物量反演精度的重要方向。

尽管草地 AGB 遥感估算研究已取得长足进展,但针对植被类型多样且包含低矮灌木的草地,特别是整体生物量的精准估算研究仍相对欠缺。现有研究多集中于单一草本或灌木类型,而忽略了草地综合生物量的准确估算。随着遥感技术的发展,多源数据融合和机器学习方法已成为生物量反演研究的重要趋势。本研究以内蒙古锡林浩特市灌木化典型草原为研究区,基于无人机 LiDAR、高光谱数据以及地面实测数据,利用 LiDAR 提取植被三维结构信息,利用高光谱数据提取光谱特征,结合逐步多元线性回归和随机森林等方法,对比分析不同模型在草地生物量反演中的应用效果及精度差异,旨在为灌木草原生物量的精准监测与可持续管理提供技术支撑。

1 材料与方法

1.1 研究区概况

锡林郭勒盟位于我国正北方,处于内蒙古自治区中部地区,是距京津冀地区最近的草原牧区,位于 42°32'~46°41'N, 111°59'~120°00'E。研究区位于内蒙古锡林郭勒盟锡林浩特市及苏尼特左旗(图 1),属于温带大陆性气候,其年均气温 0~3℃,1 月气温最低,平均 -20℃,7 月气温最高,平均 21℃。年均降水量 295 mm,由东南向西北递减。平均海拔 1000 m,地势平坦,以畜牧业为主导产业,草原资源十分丰富,草地类型属于典型草原,优势物种主要有羊草(*Leymus chinensis*)、克列门茨针茅(*Stipa krylovii* Roshev)和小叶锦鸡儿(*Caragana stenophylla* Pojark.),平均草层高度 10~30 cm,覆盖度和生物量较低,均有放牧利用。

1.2 数据获取与处理

1.2.1 地面实测数据获取 本研究的地面调查数据来自 2022 年 7 月底课题组的实地测量结果。在无人机飞行测区内,均匀布设了 99 个 1 m×1 m 的样方,其中草本样方 71 个,灌木样方 28 个。草本样方的调查指标主要包括经纬度、海拔、物种数、平均草层高度、最高草层高度、植被覆盖度、AGB 鲜重。

灌木样方则主要测量灌木坐标、冠幅等信息,以便于在无人机影像上精准定位,并同步采集相应的生物量样本。所有生物量样本均在室内 65℃烘箱中

烘干 48 h 至恒重后,测量其干物质重量。样方经纬度与海拔数据使用中海达 RTK V200 高精度基站获取,定位精度 25 mm。




图1 研究区高程分布及样地位置

Fig. 1 Elevation distribution of the study area and locations of sampling areas

注:(a)为研究区高程分布及样地位置,(b)为各样地无人机影像

Note: (a) Elevation map and plot distribution; (b) unmanned aerial vehicle images acquired for each plot

1.2.2 无人机遥感数据获取 本研究收集了 LiDAR 点云数据和高光谱无人机数据。其中, LiDAR 点云数据使用大疆 Matrice 300 搭载禅思 L1 激光雷达扫描仪进行收集,该设备可同步获取 LiDAR 点云数据和 RGB 影像,飞行参数中,航线高度设定为 100 m,飞行速度为 $5 \text{ m} \cdot \text{s}^{-1}$,旁向重叠度 60%,平均点云密度约为 $90 \text{ point} \cdot \text{m}^{-3}$;高光谱影像使用大疆 Matrice 600 搭载 Resonon Pika L 高光谱成像仪进行数据采集,光谱分辨率为 4 nm,共计获取 150 个光谱通道,空间分辨率 15 cm。此外,为确保影像质量,所有飞行均在晴朗无风、无云的天气条件下,于中午 12 时左右进行。每次飞行前,均布设黑白板用于辐射定标,各样地采样日期见表 1。

1.2.3 无人机数据预处理 激光雷达点云数据的预处理,主要使用 LiDAR360 和点云魔方软件。首先,合并同一测区的原始点云数据,通过手动裁剪和基于统计离群值的方法去除噪声和异常点。然后,采用渐进三角网滤波(PTF)算法对点云进行分类,提取地面点和植被点,分别生成数字高程模型

(DEM)和数字表面模型(DSM),进而计算得到冠层高度模型(CHM)。通过优化网格大小和距离参数,最终获得 0.25 m 分辨率的 CHM。

高光谱数据使用 ENVI 5.3 软件进行高光谱数据预处理,包括辐射定标、几何校正、条带匀色等步骤。然后,采用 Savitzky-Golay 平滑滤波对光谱反射率进行去噪处理,并结合地面调查数据提取各样方位置的光谱信息。此外,对原始光谱进行一阶微分和对数倒数变换,得到相应的原始光谱(Original spectrum, OR)、一阶微分反射率(First derivative spectrum, FD)和对数的倒数(Logarithmic inverse spectrum, 1/LOG)的反射率,为后续模型构建提供数据。

根据已有的研究,本研究将提取的特征分为三类(表 2),一是原始光谱波段及经过变换处理后的波段信息;二是基于光谱波段提取或计算得到的光谱位置及面积参数(Spectral parameters of spectral position and area, PA);三是与植被 AGB 密切相关的植被指数(Vegetation indices, VI)。

表 1 采样日期及样地分布

Table 1 Sampling date and location of sampling site

样地号 Plot ID	位置 Location	飞行日期 Flight date(日/月)	采样日期 Field work date(日/月)	样地面积 Plot area/km ²
1	112.632872°E, 44.081218°N	30/07	31/07	0.34
2	113.321425°E, 43.937808°N	28/07	29/07	0.25
3	112.650383°E, 43.727274°N	29/07	30/07	0.41
4	115.734182°E, 44.746387°N	27/07	28/07	0.20
5	116.140681°E, 44.398232°N	26/07	27/07	0.25
6	115.614990°E, 44.093861°N	24/07	25/07	0.23
7	115.742532°E, 43.826813 N	22/07	23/07	0.28

表 2 高光谱的特征名称及定义

Table 2 The names and definitions of the indicators in hyperspectral analysis

特征类型 Feature type	名称 Name	定义或公式 Definition or formula
原始光谱 Original spectrum	OR	原始光谱波段反射率
一阶微分光谱 First-order differential spectroscopy	FD	一阶微分光谱波段反射率
对数的倒数 The reciprocal of a logarithm	1/LOG	对数光谱波段反射率的倒数
光谱位置及面积参数 Spectral position and area parameters(PA)	Db	430~470 nm 蓝边内一阶微分光谱中的最大值
	Dr	620~760 nm 红边内一阶微分光谱中的最大值
	H	绿峰反射高度,计算公式为: $1 - \{[R500 + 6/17 \times (R670 - R500)]/R560\}$
	D	红谷吸收深度,计算公式为: $1 - \{R670/[R560 + 11/20 \times (R760 - R560)]\}$
	SDb	430~470 nm 蓝边波长范围内 一阶微分波段反射率值总和
	SDr	620~760 nm 红边波长范围内 一阶微分波段反射率值总和
	VI1	D/H
	VI2	$(D - H)/(D + H)$
	VI3	SDr/SDb
	VI4	$(SDr - SDb)/(SDr + SDb)$
	NDVI	$(Ri - Rj)/(Ri + Rj)$
	RVI	Ri/Rj
	EVI2	$[2.5 \times (Ri - Rj)]/(Ri + 2.4Rj + 1)$
植被指数 Vegetation index(VI)		

本研究重点关注归一化植被指数(NDVI)、比值植被指数(RVI)和增强型植被指数(EVI2)三种植被指数。由于本研究高光谱数据有 150 个波段,每种植被指数可形成 22 350 种波段组合。为提高计算效率,首先计算每种植被指数所有波段组合与地面实测 AGB 的相关系数,然后选取相关性最高的 100 种组合进行后续分析。

1.3 研究方法

1.3.1 特征筛选方法 在模型构建过程中,冗余的特征不仅增加计算成本,而且会降低模型精度。

因此,有必要对特征进行筛选。在众多特征筛选方法中,连续投影算法(Successive projections algorithm, SPA)和 Lasso(Least absolute shrinkage and selection operator)因高计算效率和强数据降维能力被广泛应用于特征筛选。SPA 基于向量空间投影,通过前向特征选择迭代选择共线性最小的特征,以有效剔除冗余信息。Lasso 则通过 L1 正则化压缩系数,以全局优化的方式迫使不重要的特征系数归零,从而进行特征筛选^[21]。本研究采用 SPA 对原始光谱及一阶微分等变换后的光谱数据进行特征波段筛选,为后续建模提供关键特征;采用 Lasso 方法

对高光谱波段组合计算得到的三种植被指数进行筛选,以降低模型复杂度。

1.3.2 建模方法 本研究分别采用逐步多元线性回归(SMR)、支持向量机回归(SVR)和随机森林(RF)三种方法构建模型,所有模型均在R语言中实现。

SMR是一种迭代算法,通过逐步选择预测变量来构建多元回归模型。在每次迭代中,根据特定准则(如AIC、BIC等)添加或删除预测变量,直至所有重要预测变量均被纳入模型,从而逐步优化模型预测性能。

SVR核心思想是构建一个最优超平面,将输入和输出空间的误差限制在 ϵ 范围内;若误差小于 ϵ ,则损失为0,否则损失为误差与阈值之差^[22],主要参数包括核函数类型(如线性、多项式、高斯径向基核函数等)、核函数系数 γ 和惩罚系数 C 。在本研究中,生物量回归模型选用高斯径向基(RBF)核函数,并通过优化 γ 和 C 参数进行多次训练,以确定最佳模型。

RF通过组合多棵决策树进行预测,通过Bootstrap抽样和随机特征选择构建多棵树,最终以平均(回归)或投票(分类)方式预测。RF的性能主要由参数 $ntree$ (决策树数量)、 $mtry$ (每个节点分裂时随机选择的特征数量)和 $maxdepth$ (决策树最大深度)决定。通常, $mtry$ 设置为特征数量的平方根,以避免过拟合。

在本研究中,对于SVR和RF模型在建模前首先对变量进行标准化处理,以消除量纲影响,采用randomForest和e1071包分别构建RF和SVR模型。在模型构建过程中,利用网格搜索法进行参数寻优,通过多次训练和参数调优,以确定最佳模型参数。由于本研究样本数量有限,采用留一交叉验证(LOOCV)进行模型训练与精度验证。LOOCV适用于本文中样本数量较小的情况,在每次建模中留下一个观测样本作为验证,其余样本进行训练,可以更加准确地评估模型预测能力。

1.3.3 精度评价指标 采用决定系数(R^2)、平均绝对误差(Mean absolute error, MAE)和均方根误差(Root mean square error, RMSE)进行精度评价。这三种精度评价指标在AGB研究中应用广泛。具体公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

式中, y_i 为实测AGB, $\hat{y}_i$ 为预测AGB; n 为样本数量; R^2 表示预测值与实测值的拟合程度;MAE和RMSE表示预测值与实测值之间的误差,但RMSE对异常值更敏感。

2 结果与分析

2.1 特征选取结果

本研究基于CHM计算结果提取了99个地面样方对应的草层高度特征,包括平均高度(H_{mean})、最大高度(H_{max})、最小高度(H_{min})、高度范围(H_{range})和标准差(H_{std}),并分别针对草本和灌木样方进行了对比分析(图2)。结果显示,草本样方CHM提取的冠层高度与地面实测值的相关性较弱。其中,平均高度(H_{mean})与实测值的相关系数最高($r=0.50$),其次是最大高度(H_{max} , $r=0.48$),最小高度的相关性最低。普遍较低的草层高度(多数低于50 cm,部分甚至低于20 cm)可能导致了较弱的相关性。这可能是由于激光雷达传感器在低矮植被区域的系统误差更为显著。

草本样方中(图2a),相关性分析结果显示, H_{max} 、 H_{mean} 和 H_{range} 与AGB存在极显著相关性($P<0.01$),而其余几个特征与AGB的相关性不显著,相关系数从大到小依次为 H_{mean} (0.62)、 H_{max} (0.56)、 H_{range} (0.46)、DEM、 H_{min} 、 H_{std} 、slope、 I_{mean} 。

对于灌木样方(图2b),相关性分析结果显示, H_{max} 、 H_{mean} 、 H_{range} 、 H_{std} 、体积(Volume)和 I_{sum} 与AGB存在极显著相关性($P<0.01$),其余特征与AGB关系不显著。相关系数从大到小依次为:Volume(0.78)、雷达强度和(I_{sum})和 H_{range} (0.67)、 H_{std} 、 H_{max} 。

为提高模型效率和性能,降低高光谱数据的维度和冗余,本研究采用SPA法对原始光谱、一阶微分和对数倒数等对光谱特征进行了筛选(表3)。对于草本样方的高光谱数据,提取了OR的7个波段,1/LOG的5个波段以及FD的6个波段;而灌木样方则OR、1/LOG和FD均筛选了7个波段。




图 2 LiDAR 草本样方(a)和灌木样方(b)提取结果与 AGB 相关性结果

Fig. 2 The extraction results of LiDAR herbaceous plot (a) and shrub plot (b) and the correlation results with AGB

注:*, $P<0.05$; **, $P<0.01$

Note: *, $P<0.05$; **, $P<0.01$

表 3 高光谱特征波段筛选结果

Table 3 The screening results of hyperspectral characteristic bands

光谱类型 Spectral type	样方类型 Sample type	原波段数 Original number of frequency bands	筛选波段数量 Number of selected bands	具体波段 Band	均方根 误差 RMSE/ ($\text{g}\cdot\text{m}^{-2}$)
原始波段 Original band(OR)	草本 Herbaceous	146	7	992,678,974,926,532,957,401	19.53
	灌木 Shrub		7	983,988,491,961,397,939,678	118.74
对数的倒数 The reciprocal of a logarithm(1/LOG)	草本 Herbaceous	146	5	678,921,997,519,943	18.41
	灌木 Shrub		7	988,983,961,491,939,759,397	123.85
一阶微分 First-order differential(FD)	草本 Herbaceous	146	6	700,528,397,988,811,974	18.36
	灌木 Shrub		7	957,895,816,401,917,873,751	123.57

从植被指数的组合来看(表 4),筛选出的植被指数主要集中在 B80~B100 波段范围(710~812 nm),对应于红光和近红外光的交界区域,同时也是

灌木和草本光谱反射率曲线的交叉区域。这一结果表明,筛选出的植被指数能够反映植被的生物量水平。

表 4 高光谱植被指数筛选结果

Table 4 The screening results of hyperspectral vegetation indices

植被指数 Vegetation index	样方类型 Sample type	组合方式 Combination method	R^2	标准化后的 RMSE/ Standardized RMSE
RVI	草本 Herbaceous	$B_{92}B_{86}, B_{92}B_{87}, B_{98}B_{89}, B_{116}B_{89}, B_{124}B_{81}, B_{124}B_{90}$	0.83	0.40
	灌木 Shrub	$B_{81}B_{43}, B_{88}B_{41}$	0.68	0.55
EVI	草本 Herbaceous	$B_{42}B_{45}, B_{53}B_{55}, B_{54}B_{56}, B_{56}B_{59}, B_{81}B_{80}, B_{92}B_{85}, B_{114}B_{86}$	0.83	0.41
	灌木 Shrub	$B_{14}B_{17}, B_{88}B_{85}$	0.63	0.59
NDVI	草本 Herbaceous	$B_{92}B_{87}, B_{98}B_{87}, B_{111}B_{89}, B_{117}B_{89}, B_{124}B_{66}$	0.83	0.41
	灌木 Shrub	$B_{76}B_{66}, B_{81}B_{43}, B_{86}B_{35}, B_{88}B_{84}, B_{95}B_{38}$	0.80	0.44

2.2 AGB 遥感建模与精度评价

2.2.1 基于高光谱 PA 与 VI 特征的模型构建与精度评价 相较于仅使用原始波段及其简单变换形式,本研究进一步将波段数据组合为多种植被指

数,并经筛选后作为 SMR、SVR 和 RF 三种模型的输入变量。这一策略旨在更全面地利用高光谱信息,并提升模型精度。

草本高光谱建模结果中(表 5),VI 的精度优于

PA, VI 的 SVR 和 RF 模型 R^2 均为 0.84, 而 PA 的最佳模型 SVR 的 R^2 为 0.82, 低于 VI 模型 0.02, 且 RMSE 和 MAE 也较高。将 VI 与 PA 组合后的模型表现明显提高, 组合模型的最佳结果为 RF, R^2 为 0.87, 较 VI 的 RF 提高了 0.03, RMSE 和 MAE 分别降低了 $2.03 \text{ g}\cdot\text{m}^{-2}$ 和 $1.44 \text{ g}\cdot\text{m}^{-2}$ 。从建模方法来看, 最优模型均为机器学习, 其中 VI 和 VI+PA 的最优模型为 RF, PA 的最优模型为 SVR。尽管 VI 和 VI+PA 的最佳模型为 RF, 但 SVR 的表现也相当不错, 差异不大。例如, 在 VI+PA 组合模型中, SVR 的 R^2 为 0.86, 仅比 RF 低 0.01, 且 RMSE 和 MAE 也相差不大, 分别仅高 $0.57 \text{ g}\cdot\text{m}^{-2}$ 和 $0.26 \text{ g}\cdot\text{m}^{-2}$ 。

灌木高光谱 PA 与 VI 特征的建模结果中(表

5), VI+PA 组合特征的模型表现仍优于单独使用 VI 或 PA, 但 SMR 模型因出现负值而无法使用。基于 VI 和 PA 的 RF 模型表现最优, 其 R^2 分别为 0.35~0.40 和 0.23~0.43, 相比其他模型精度有显著的提升。在不同特征的建模中, RF 模型表现最好, VI 的 R^2 为 0.40, RMSE 和 MAE 分别为 $154.76 \text{ g}\cdot\text{m}^{-2}$ 和 $118.03 \text{ g}\cdot\text{m}^{-2}$; PA 的 RF 模型 R^2 为 0.43, RMSE 和 MAE 分别为 $149.38 \text{ g}\cdot\text{m}^{-2}$ 和 $119.22 \text{ g}\cdot\text{m}^{-2}$; VI+PA 组合特征的 RF 模型 R^2 为 0.44, RMSE 和 MAE 分别为 $147.50 \text{ g}\cdot\text{m}^{-2}$ 和 $114.98 \text{ g}\cdot\text{m}^{-2}$ 。SVR 模型在各特征下表现稍逊, R^2 普遍低于 RF, 但与 RF 差距不大。SMR 模型精度较差, 特别是在 PA 中, R^2 仅为 0.23, RMSE 和 MAE 也相对偏大。

表 5 基于光谱敏感特征的逐步多元线性回归与机器学习模型结果

Table 5 The results of stepwise multiple linear regression and machine learning models based on spectral sensitive indicators

类型 Type	特征 Feature	建模方法 Modeling method	验证集 R^2 Validation set R^2	均方根误差 RMSE/ ($\text{g}\cdot\text{m}^{-2}$)	平均绝对误差 MAE/ ($\text{g}\cdot\text{m}^{-2}$)
草本 Herbaceous	VI	SMR	0.79	23.82	18.92
		SVR	0.84	22.00	15.70
		RF	0.84	21.55	16.00
	PA	SMR	0.74	26.81	20.26
		SVR	0.82	22.90	16.99
		RF	0.80	24.16	17.43
	VI+PA	SMR	0.76	26.70	20.51
		SVR	0.86	20.09	14.82
		RF	0.87	19.52	14.56
灌木 Shrub	VI	SMR	0.35	160.53	108.60
		SVR	0.35	161.42	121.60
		RF	0.40	154.76	118.03
	PA	SMR	0.23	202.98	157.49
		SVR	0.40	154.39	118.16
		RF	0.43	149.38	119.22
	VI+PA	SVR	0.38	157.60	116.16
		RF	0.44	147.50	114.98

注: VI+PA 为植被指数特征结合光谱位置及面积参数特征

Note: VI+PA denotes the feature set combining vegetation index characteristics with spectral position and area parameters

草本和灌木最优模型的预测结果如图 3 显示, 草本散点图中的拟合线与 1:1 线几乎重合(图 3a), 表明 AGB 预测效果良好。而灌木精度一般(图 3c), 散点图趋势线与 1:1 线具有一定夹角, 存在高值低估和低值高估的现象; 小提琴图显示(图 3d), AGB 预测平均值较实测值略高, 但预测范围偏窄, 主要集中在 $100\sim650 \text{ g}\cdot\text{m}^{-2}$ 之间。

2.2.2 基于高光谱特征波段和衍生特征 PA 和 VI 的模型与精度评价 光谱特征波段和 PA 和 VI 等光谱衍生的特征在模型中均取得了较好的效果, 因此将前两节的相应特征进行组合, 用于模型的输入

以此构建 SMR、SVR 和 RF 模型。

草本建模结果中(表 6), 草本特征组合“植被指数特征+光谱位置及面积参数特征+原始光谱特征(VI+PA+OR)”的最优模型为 SVR, R^2 为 0.85, RMSE 和 MAE 分别为 $21.06 \text{ g}\cdot\text{m}^{-2}$ 和 $15.55 \text{ g}\cdot\text{m}^{-2}$, RF 模型精度稍逊, R^2 为 0.84; 组合“植被指数特征+光谱位置及面积参数特征+原始光谱倒数变换特征(VI+PA+1/LOG)”的最优模型为 RF, R^2 为 0.86, RMSE 和 MAE 分别为 $20.30 \text{ g}\cdot\text{m}^{-2}$ 和 $15.01 \text{ g}\cdot\text{m}^{-2}$, SVR 稍低; 组合“植被指数特征+光谱位置及面积参数特征+原始光谱一阶微分变换




图 3 草本和灌木基于 VI+PA 特征的 RF 模型的散点图和小提琴图

Fig. 3 Scatter plots and violin plots based on the RF model of VI+PA indicators for herbaceous plants and shrub plants

注: (a) 和 (c) 为草本与灌木拟合散点图; (b) 和 (d) 为样本分布小提琴图

Note: (a) and (c) are the scatter plots showing the model fits for herbaceous plants and shrubs, respectively; (b) and (d) are the violin plots illustrating the sample distributions

特征 (VI+PA+FD) 的最优模型为 RF, R^2 为 0.87, RMSE 和 MAE 分别为 $19.05 \text{ g} \cdot \text{m}^{-2}$ 和 $14.40 \text{ g} \cdot \text{m}^{-2}$, SVR 表现较差, R^2 为 0.81。

灌木的建模结果中 (表 6), VI+PA+FD 组合表现最佳, 明显优于其他两种组合。各组合中, RF 与 SVR 模型的精度差异不大, 但最优模型均为 RF。在每个特征模型中, VI+PA+OR 和 VI+PA+1/LOG 的最佳模型均为 RF, 且 R^2 均为 0.39, RMSE 分别为 $155.03 \text{ g} \cdot \text{m}^{-2}$ 和 $155.11 \text{ g} \cdot \text{m}^{-2}$; SVR 的性能略逊色, R^2 分别为 0.37 和 0.34。对于 VI+PA+FD, RF 模型表现最佳, R^2 为 0.47, RMSE 和 MAE 分别为 $143.67 \text{ g} \cdot \text{m}^{-2}$ 和 $109.92 \text{ g} \cdot \text{m}^{-2}$, SVR 与 RF 结果相似, R^2 相同, 但 RMSE 和 MAE 稍高。

图 4 显示, 草本最优模型的预测结果较为理想, 散点图趋势线与 1:1 线夹角较小 (图 4a), 但与 VI+PA 结果相比没有显著提升。小提琴图显示

(图 4b), AGB 预测值与实测值较为接近, 但仍存在高值区域缺失和平均值略偏高的问题, 整体效果较好。灌木散点图趋势线与 1:1 线仍有一定夹角, 表明对高值区域低估、低值区域高估 (图 4c)。小提琴图显示 (图 4d), AGB 预测值的平均值偏高, 且预测范围与实测值接近, 主要集中在 $200 \text{ g} \cdot \text{m}^{-2}$ 左右。

2.2.3 基于激光雷达逐步多元线性回归和机器学习的建模 草本和灌木 LiDAR 建模结果如表 7 所示, 对于草本 LiDAR 信息中提取的特征指标, SVR 模型优于 RF 与 SMR, 模型的 R^2 为 0.24, 高于 RF 和 SMR 的 0.21, 同时 RMSE 与 MAE 也具有一定优势, RMSE 为 $47.65 \text{ g} \cdot \text{m}^{-2}$, 比 SMR 的 47.86 略低了 $0.21 \text{ g} \cdot \text{m}^{-2}$ 。MAE 为 $42.11 \text{ g} \cdot \text{m}^{-2}$, 与精度较好的 RF 相比也低了 $0.16 \text{ g} \cdot \text{m}^{-2}$ 。灌木 RF 精度最高, R^2 为 0.58, RMSE 与 MAE 相较 SVR 模型均略低。

表 6 基于特征波段和敏感光谱特征的建模结果

Table 6 Modeling results based on feature bands and sensitivity spectral indicators

类型 Type	特征 Feature	建模方法 Modeling method	验证集 R^2 Validation set R^2	均方根误差 RMSE/($\text{g}\cdot\text{m}^{-2}$)	平均绝对误差 MAE/($\text{g}\cdot\text{m}^{-2}$)
草本 Herbaceous	VI+PA+OR	SMR	0.72	29.37	23.36
		SVR	0.85	21.06	15.55
		RF	0.84	21.67	15.44
	VI+PA+1/LOG	SMR	0.73	28.77	22.66
		SVR	0.85	20.67	15.28
		RF	0.86	20.30	15.01
	VI+PA+FD	SMR	0.70	30.67	24.13
		SVR	0.81	23.54	18.12
		RF	0.87	19.05	14.40
灌木 Shrub	VI+PA+OR	SVR	0.37	159.28	125.11
		RF	0.39	155.03	121.36
	VI+PA+1/LOG	SVR	0.34	162.38	128.53
		RF	0.39	155.11	120.29
	VI+PA+FD	SVR	0.47	153.43	114.81
		RF	0.47	143.67	109.92




图 4 基于草本和灌木 VI+PA+FD 组合 RF 模型散点图和小提琴图

Fig. 4 Scatter plots and violin plots of RF models based on herbaceous and shrubby VI+PA+FD combinations

注:(a)和(c)为草本与灌木拟合散点图;(b)和(d)为样本分布小提琴图

Note:(a) and (c) are the scatter plots showing the model fits for herbaceous plants and shrubs , respectively. (b) and (d) are the violin plots illustrating the sample distributions

表 7 基于 LiDAR 的 AGB 建模结果

Table 7 Modeling results of AGB based on LiDAR

特征 Feature	建模方法 Modeling method	验证集 R^2 Validation set R^2	均方根误差 RMSE/($\text{g}\cdot\text{m}^{-2}$)	平均绝对误差 MAE/($\text{g}\cdot\text{m}^{-2}$)
草本 LiDAR/ Herbaceous LiDAR	SMR	0.21	47.86	42.11
	SVR	0.24	47.65	39.32
	RF	0.21	47.94	39.48
灌木 LiDAR/ Shrub LiDAR	SMR	0.46	157.65	119.29
	SVR	0.43	150.20	122.02
	RF	0.58	129.64	106.30

草本和灌木最优模型的预测结果显示(图 5),草本 AGB 预测值与实测值的趋势线夹角较大(图 5a),散点分布范围广,存在明显的高值低估和低值高估现象。小提琴图显示(图 5b),AGB 预测平均值低于实测值,最高值偏低,预测范围略小。通过相关性检验提取的灌木特征(表 7),使用 SMR、SVR 和 RF 方法建模后,结果表明 RF 模型优于 SMR 和 SVR, R^2 为 0.58,明显高于 SMR 的 0.46 和 SVR 的 0.43,且 RMSE($129.64\text{ g}\cdot\text{m}^{-2}$)和 MAE($106.30\text{ g}\cdot\text{m}^{-2}$)分别比 SVR 低 $20.56\text{ g}\cdot\text{m}^{-2}$ 和比 SMR 低 $12.99\text{ g}\cdot\text{m}^{-2}$ 。灌木方面单独体积特征的建模结果较为接近 1:1 线(图 5c),散点图和趋势线夹角较小,尽管存在高值低估和低值高估现象。小提琴图显示(图 5d),AGB 预测值的范围与实测值接近,仅最低值稍高。平均值偏高,约为 $200\text{ g}\cdot\text{m}^{-2}$ 。

2.2.4 多源数据融合的模型构建和精度评价 结合高光谱和 LiDAR 数据中的高度、强度、坡度等多维特征,使用 RF 和 SVR 进行建模并计算精度(表 8)。对于草本,综合多源数据建模的结果显示,RF 模型的精度优于 SVR,并且与仅使用高光谱单一数据源的模型相比,RF 模型的精度有所提升,而 SVR 模型的精度没有改善,甚至略有下降。其中,草本最优模型的特征组合 VI+PA+FD+LiDAR 的 RF 模型, R^2 为 0.88, RMSE 为 $18.47\text{ g}\cdot\text{m}^{-2}$, MAE 为 $14.22\text{ g}\cdot\text{m}^{-2}$; SVR 模型稍逊, R^2 为 0.75, RMSE 为 $27.86\text{ g}\cdot\text{m}^{-2}$, MAE 为 $20.63\text{ g}\cdot\text{m}^{-2}$ 。特征组合 VI+PA+OR+LiDAR 的 RF 模型结果稍差, R^2 为 0.87, RMSE 为 $19.39\text{ g}\cdot\text{m}^{-2}$, MAE 为 $14.71\text{ g}\cdot\text{m}^{-2}$; SVR 模型 R^2 为 0.79, RMSE 为 $25.25\text{ g}\cdot\text{m}^{-2}$, MAE 为 $18.18\text{ g}\cdot\text{m}^{-2}$ 。特征组合 VI+PA+1/LOG+LiDAR 的 RF 模型与 VI+PA+OR+LiDAR 相似, R^2 为 0.87, RMSE 为 $19.43\text{ g}\cdot\text{m}^{-2}$, MAE 为 $14.75\text{ g}\cdot\text{m}^{-2}$, SVR 模型 R^2 为 0.80, RMSE 为 $24.66\text{ g}\cdot\text{m}^{-2}$, MAE 为 $17.84\text{ g}\cdot\text{m}^{-2}$ 。对于灌木,融合多源数据建模结果显示 RF 模型优于 SVR,且与加入 LiDAR 特征前

的结果相比,RF 精度有所提升,而 SVR 精度略有下降。最优模型为 VI+PA+FD+LiDAR 组合的 RF 模型, R^2 为 0.64, RMSE 为 $117.79\text{ g}\cdot\text{m}^{-2}$, MAE 为 $94.09\text{ g}\cdot\text{m}^{-2}$; SVR 模型较差, R^2 为 0.31, RMSE 为 $169.05\text{ g}\cdot\text{m}^{-2}$, MAE 为 $129.38\text{ g}\cdot\text{m}^{-2}$ 。VI+PA+OR+LiDAR 组合的 RF 模型结果稍逊, R^2 为 0.60, RMSE 为 $123.89\text{ g}\cdot\text{m}^{-2}$, MAE 为 $101.46\text{ g}\cdot\text{m}^{-2}$, SVR 模型 R^2 为 0.29, RMSE 为 $168.76\text{ g}\cdot\text{m}^{-2}$, MAE 为 $135.10\text{ g}\cdot\text{m}^{-2}$ 。VI+PA+1/LOG+LiDAR 组合的 RF 模型与上述相近, R^2 为 0.59, RMSE 为 $124.93\text{ g}\cdot\text{m}^{-2}$, MAE 为 $101.86\text{ g}\cdot\text{m}^{-2}$, SVR 模型 R^2 为 0.26, RMSE 为 $172.37\text{ g}\cdot\text{m}^{-2}$, MAE 为 $138.75\text{ g}\cdot\text{m}^{-2}$ 。

草本和灌木最优模型的预测结果如图 6 显示,草本散点图与 1:1 线接近(图 6a),预测效果较好,虽有轻微高值低估,从小提琴图看(图 6b),AGB 预测值与实测值形态相似,平均值略高,最高值偏低。灌木趋势线与 1:1 线有夹角(图 6c),精度有所提升,尽管仍有高值低估和低值高估的情况;从小提琴图看(图 6d),预测值与实测值形状相似,平均值略高,预测范围偏小,且高值区间偏低。

3 讨论

3.1 LiDAR 和高光谱特征对灌丛植被草原 AGB 估算的敏感性

本研究基于无人机多源遥感数据(激光雷达、高光谱)和地面实测数据,对具有灌丛植被的草原 AGB 估算模型进行了深入探究。研究结果揭示草本和灌木 AGB 对不同类型遥感数据的敏感性存在显著差异,为精准估算复杂植被结构下的 AGB 提供了新的视角和方法。在特征筛选过程中, LiDAR 数据分析表明,草本和灌木 AGB 与草层高度信息呈显著相关,其中平均草层高度被确定为最佳预测因子。然而,多数研究表明^[23-25],无人机 LiDAR 在估算草本植被高度时存在低估现象,这可能归因于研究区内草本植物的低矮特性,强度差异不明显,导致强




图5 基于草本和灌木LiDAR特征SVR和RF模型的散点图和小提琴图

Fig. 5 Scatter plots and violin plots of SVR and RF models based on LiDAR indicators of herbaceous plants and shrub plants

注:(a)和(c)为草本与灌木拟合散点图;(b)和(d)为样本分布小提琴图

Note: (a) and (c) are the scatter plots showing the model fits for herbaceous plants and shrubs, respectively. (b) and (d) are the violin plots illustrating the sample distributions

度信息在估算草本高度时敏感性较差。草本植被高度的低估进一步影响Lidar对草本AGB的敏感性。相比之下,Chen等^[26]研究表明对于高度较高且冠层三维结构明显的灌木,UAV LiDAR仍可以通过计算体积精准的预测灌木AGB。本研究中灌木的体积信息与AGB的相关性最为显著,表明LiDAR数据在捕捉灌木的三维结构特征方面具有优势,这与Chen等^[26]研究结果相一致。高光谱数据分析进一步揭示,与AGB相关性最高的植被指数组合主要集中在 $B_{80} \sim B_{100}$ 波段范围(对应710~812 nm),恰好位于红光和近红外的过渡区域,同时也是灌木和草本光谱反射率曲线的交汇区域。这一发现具有重要的生态学意义,它表明红边区域的光谱信息对于区分草本和灌木,以及准确估算AGB具有关键作用。红边区域对植被叶绿素含量、冠层结构

和健康状况高度敏感,能够反映植被的光合作用能力和生理状态。

3.2 多特征融合在灌丛植被草原AGB中的监测潜力

由于灌丛与草本在生理、形态等方面存在较大差异,因此,本研究为提高AGB估算精度,采取了针对草本和灌木分别构建模型的策略。结果表明,基于高光谱数据的草本AGB模型具有较高的精度($R^2=0.87$),显著优于LiDAR模型($R^2=0.24$)。将LiDAR数据与高光谱数据融合后,草本AGB模型的精度再次略有提升(R^2 从0.87提升至0.88),这表明LiDAR提供的三维结构信息对草本AGB估算具有一定的补充作用。然而,对于灌木而言,基于LiDAR数据的AGB估算模型表现出更高的精度

表 8 基于 LiDAR 和高光谱特征的机器学习模型结果

Table 8 Results of machine learning models based on LiDAR and hyperspectral indicators

类型 Type	特征 Feature	建模方法 Modeling method	验证集 R^2 Validation set R^2	均方根误差 RMSE/($\text{g} \cdot \text{m}^{-2}$)	平均绝对误差 MAE/($\text{g} \cdot \text{m}^{-2}$)
草本 Herbaceous	VI+PA+OR+LiDAR	SVR	0.79	25.25	18.18
		RF	0.87	19.39	14.71
	VI+PA+1/LOG+LiDAR	SVR	0.80	24.66	17.84
		RF	0.87	19.43	14.75
	VI+PA+FD+LiDAR	SVR	0.75	27.86	20.63
		RF	0.88	18.47	14.22
灌木 Shrub	VI+PA+OR+LiDAR	SVR	0.29	168.76	135.10
		RF	0.60	123.89	101.46
	VI+PA+1/LOG+LiDAR	SVR	0.26	172.37	138.75
		RF	0.59	124.93	101.86
	VI+PA+FD+LiDAR	SVR	0.31	169.05	129.38
		RF	0.64	117.79	94.09

注: VI+PA+OR+LiDAR 代表植被指数+光谱位置及面积参数+原始光谱+LiDAR 特征组合; VI+PA+1/LOG+LiDAR 代表植被指数+光谱位置及面积参数+原始光谱倒数变换+LiDAR 特征组合; VI+PA+FD+LiDAR 代表植被指数+光谱位置及面积参数+原始光谱一阶微分变换+LiDAR 特征组合

Note: VI+PA+OR+LiDAR stands for the combination of VI, PA, OR and LiDAR features; VI+PA+1/LOG+LiDAR stands for the combination of VI, PA, 1/LOG and LiDAR features; and VI+PA+FD+LiDAR stands for the combination of VI, PA, FD and LiDAR features

($R^2=0.58$), 而高光谱模型的精度相对较低($R^2=0.47$), 将两种数据融合后, 灌木 AGB 模型的精度得到明显提升(R^2 从 0.58 提升至 0.64), 且提升幅度高于草本。这一结果与 Zhao 等的研究结论相符^[6], 即无人机多光谱和 LiDAR 数据的融合可以有效提高灌丛植被的识别精度。

3.3 模型精度差异分析

基于不同遥感数据源的草本和灌木 AGB 模型精度的差异, 可归因于植被结构和光谱特性的内在差异。研究区草地类型以温性草原类和温性荒漠草原类为主, 草本植被较低矮(平均高度 $H_{\text{mean}}=14.53 \text{ cm}$)且覆盖度较低(平均覆盖度 $\text{FVC}_{\text{mean}}=26.35\%$), 而本研究所计算 CHM 特征空间分辨率为 0.25 m。过低的草本高度导致 LiDAR 冠层高度和强度信息对植被变化的敏感性降低, 从而影响了 AGB 的反演精度, 这与已有研究相符^[23-25]。相比之下, 高空间分辨率的高光谱数据能够提供精细且连续的植被光谱, 可有效捕捉草本植物生长状况的细微光谱差异, 并在一定程度上反映植被生理状况^[27-28]。此外, 高光谱中对植被敏感的红边波段能够提供更多的草地长势信息, 因此高光谱数据在草本 AGB 估算中表现出更高的精度^[29-30]。对于灌木而言, 其平均高度较高($H_{\text{mean}}=39.29 \text{ cm}$)且覆盖度较高($\text{FVC}_{\text{mean}}=53.83\%$), 使得 LiDAR 提取的冠层

高度和强度信息成为 AGB 估算的关键因子。尽管灌木的高光谱信息模型精度低于 LiDAR 模型, 且低于草本的高光谱模型, 但这可能与灌木样方数量相对较少有关。未来的研究将考虑扩大样本量, 进一步验证和优化灌木 AGB 估算模型。

4 结论

本研究基于 LiDAR 与高光谱无人机数据结合机器学习方法探究了多源数据特征融合在内蒙古典型草原 AGB 监测中的适用性, 研究取得以下主要结论:

(1) 通过对比不同传感器特征对灌丛草原敏感性分析结果表明, LiDAR 数据中的草层高度信息对草本和灌丛均具有极显著相关性, 平均草层高度是预测草地 AGB 的最佳特征。(2) LiDAR 强度信息对草本 AGB 的估算贡献有限。对于灌木, LiDAR 体积信息与 AGB 的相关性最为显著。高光谱数据分析进一步揭示, 红边波段(710~812 nm)的植被指数组合与 AGB 相关性最高, 对准确估算 AGB 具有关键作用。(3) 基于多源数据融合的草本和灌木最优 AGB 估算模型均为 VI+PA+FD+LiDAR 组合的 RF 模型。高光谱数据在草本 AGB 估算中表现出显著优势, 优于 LiDAR 模型; 而 LiDAR 数据在灌木 AGB 估算中更为有效。多源遥感数据的融合能够进一步提高 AGB 估算精度, 尤其对于灌木而言, 融合 LiDAR 和




图6 基于草本和灌木 VI+PA+FD+LiDAR 组合 RF 模型的散点图和小提琴图

Fig. 6 Scatter plots and violin plots of the RF model based on the combination of herbaceous plants and shrubs VI+PA+FD+LiDAR

注:(a)和(c)为草本与灌木拟合散点图;(b)和(d)为样本分布小提琴图

Note:(a) and (c) are the scatter plots showing the model fits for herbaceous plants and shrubs, respectively. (b) and (d) are the violin plots illustrating the sample distributions

高光谱数据后,模型精度提升幅度显著高于草本。

随着传感器参数的提升,未来可采用更高分辨率的超光谱数据和更高密度的 LiDAR 点云数据以进一步降低由分辨率导致的模型监测误差,以期草原灌木入侵等提供更加精确的监测结果。

参考文献

- [1] 方精云,杨元合,马文红,等. 中国草地生态系统碳库及其变化[J]. 中国科学: 生命科学,2010,40(7):566-576
FANG J Y, YANG Y H, MA W H, et al. Ecosystem carbon stocks and their changes in China's grasslands[J]. SCIENTIA SINICA Vitae,2010,40(7):566-576
- [2] GRÜN A L, STRASKRABA S, SCHULZ S, et al. Long-term effects of environmentally relevant concentrations of silver nanoparticles on microbial biomass, enzyme activity, and functional genes involved in the nitrogen cycle of loamy soil[J]. Journal of Environmental Sciences,2018,69:12-22
- [3] LIU Z, CHEN R, SONG Y, et al. Aboveground biomass and water storage allocation in alpine willow shrubs in the Qilian Mountains in China[J]. Journal of Mountain Science,2015,12(1):207-217
- [4] 徐斌,杨秀春,侯向阳,等. 草原植被遥感监测方法研究进展[J]. 科技导报,2007(9):5-8
XU B, YANG X C, HOU X Y, et al. Advance of technology of remote sensing monitoring for grassland vegetation[J]. Science & Technology Review,2007(9):5-8
- [5] KNAPP N, FISCHER R, CAZCARRA-BES V, et al. Structure metrics to generalize biomass estimation from LiDAR across forest types from different continents[J]. Remote Sensing of Environment,2020,237:111597
- [6] ZHAO Y J, LIU X L, WANG Y, et al. UAV-based individual shrub aboveground biomass estimation calibrated against terrestrial LiDAR in a shrub-encroached grassland[J]. International Journal of Applied Earth Observation and Geoinformation,2021,101:102358

- [7] 金云翔,徐斌,杨秀春,等. 内蒙古锡林郭勒盟草原草量动态遥感估算[J]. 中国科学:生命科学,2011,41(12):1185-1195
JIN Y X, XU B, YANG X C, et al. Remote sensing dynamic estimation of grass production in Xilinguole, Inner Mongolia [J]. SCIENTIA SINICA Vitae, 2011, 41(12):1185-1195
- [8] HE L, LI A N, YIN G F, et al. Retrieval of Grassland Above-ground Biomass through Inversion of the PROSAIL Model with MODIS Imagery[J]. Remote Sensing, 2019, 11(13):1597
- [9] 高宏元,侯蒙京,葛静,等. 基于随机森林的高寒草地上生物量高光谱估算[J]. 草地学报,2021,29(8):1757-1768
GAO H Y, HOU M J, GE J, et al. Hyperspectral Estimation of Aboveground Biomass of Alpine Grassland based on Random Forest Algorithm[J]. Acta Agrestia Sinica, 2021, 29(8):1757-1768
- [10] 邢晓语,杨秀春,徐斌,等. 基于随机森林算法的草原地上生物量遥感估算方法研究[J]. 地球信息科学学报,2021,23(7):1312-1324
XING X Y, YANG X C, XU B, et al. Remote sensing estimation of grassland aboveground biomass based on random forest [J]. Journal of Geo-information Science, 2021, 23(7):1312-1324
- [11] SHEN X J, LIU Y W, LIU B H, et al. Effect of shrub encroachment on land surface temperature in semi-arid areas of temperate regions of the Northern Hemisphere[J]. Agricultural and Forest Meteorology, 2022, 320:108943
- [12] BAZEZE M N, HUSSIN Y A, KLOOSTERMAN E H. Integrating Airborne LiDAR and Terrestrial Laser Scanner forest parameters for accurate above-ground biomass/carbon estimation in Ayer Hitam tropical forest, Malaysia[J]. International Journal of Applied Earth Observation and Geoinformation, 2018, 73:638-652
- [13] 郭庆华,刘瑾,陶胜利,等. 激光雷达在森林生态系统监测模拟中的应用现状与展望[J]. 科学通报,2014,59(6):459-478
GUO Q H, LIU J, TAO S L, et al. Perspectives and prospects of LiDAR in forest ecosystem monitoring and modeling [J]. Chinese Science Bulletin, 2014, 59(6):459-478
- [14] 姚兴成,曲恬甜,常文静,等. 基于MODIS数据和植被特征估算草地生物量[J]. 中国生态农业学报,2017,25(4):530-541
YAO X C, QU Y T, CHANG W J, et al. Estimation of grassland biomass using MODIS data and plant community characteristics [J]. Chinese Journal of Eco-Agriculture, 2017, 25(4):530-541
- [15] 杨淑霞,张文娟,冯胜琦,等. 基于MODIS逐日地表反射率数据的青南地区草地生长状况遥感监测研究[J]. 草业学报,2016,25(8):14-26
YANG S X, ZHANG W J, FENG Q S, et al. Monitoring of grassland herbage accumulation by remote sensing using MODIS daily surface reflectance data in the Qingnan Region [J]. Acta Prataculturae Sinica, 2016, 25(8):14-26
- [16] 宋柯馨,蒋馥根,胡宗达,等. 西藏自治区草地上生物量遥感反演研究[J]. 生态学报,2023,43(13):5600-5613
SONG K X, JIANG F G, HU Z D, et al. Remote sensing inversion of above-ground biomass of grassland in the Tibet Autonomous Region. Acta Ecologica Sinica, 2023, 43(13):5600-5613
- [17] 黄家兴,吴静,李纯斌,等. 基于Sentinel-2和Landsat 8数据的天祝县草地上生物量遥感反演[J]. 草地学报,2021,29(9):2023-2030
HUANG J X, WU J, LI C B, et al. Remote sensing retrieval of grassland above-ground biomass in tianzhu county based on Sentinel-2 and Landsat 8 data[J]. Acta Agrestia Sinica, 2021, 29(9):2023-2030
- [18] 童新,杨震雷,张亦然,等. 基于不同阶微分高光谱植被指数的牧区草地上生物量估算[J]. 草地学报,2022,30(9):2438-2448
TONG X, YANG Z L, ZHANG Y R, et al. Estimation of pasture aboveground biomass using different orders of differential hyperspectral vegetation indices [J]. Acta Agrestia Sinica, 2022, 30(9):2438-2448
- [19] 张亦然,刘廷玺,童新,等. 基于XGBoost算法的草甸地上生物量的高光谱遥感反演[J]. 草业学报,2021,30(4):1-12
ZHANG Y R, LIU Y X, TONG X, et al. Hyperspectral remote sensing inversion of meadow aboveground biomass based on an XGBoost algorithm[J]. Acta Prataculturae Sinica, 2021, 30(4):1-12
- [20] 殷晓飞,王春光,王海超,等. 基于高光谱特征参数荒漠草原生物量估测研究[J]. 农机化研究,2018,40(10):154-159
YIN X F, WANG C G, WANG H C, et al. Study on biomass estimation of desert steppe based on hyperspectral characteristic [J]. Journal of Agricultural Mechanization Research, 2018, 40(10):154-159
- [21] TIBSHIRANI R. Regression shrinkage and selection via the lasso[J]. Journal of the Royal Statistical Society Series B: Statistical Methodology, 1996, 58(1):267-288
- [22] VAPNIK V N. The nature of statistical learning theory [M]. Cham:Springer New York, 2000:156-163
- [23] CHEN A, WANG X, ZHANG M, et al. Fusion of LiDAR and multispectral data for aboveground biomass estimation in mountain grassland[J]. Remote Sensing, 2023, 15:405
- [24] XU C, ZHAO D, ZHENG Z, et al. Correction of UAV LiDAR-derived grassland canopy height based on scan angle [J]. Frontiers in Plant Science, 2023, 14:1108109
- [25] 许开宏,施招,马磊超,等. 基于机载激光雷达与高景一号数据的草原地上生物量反演研究[J]. 草业学报,2023,32(5):40-49
XU K H, SHI Z, MA L C, et al. Retrieval of grassland above-ground biomass based on airborne LiDAR and SuperView-1 data [J]. Acta Prataculturae Sinica, 2023, 32(5):40-49
- [26] CHEN A, XU C, ZHANG M, et al. Cross-scale mapping of above-ground biomass and shrub dominance by integrating UAV and satellite data in temperate grassland [J]. Remote Sensing of Environment, 2024, 304:114024
- [27] 乌兰吐雅,包刚,乌云德吉,等. 草地上生物量高光谱遥感估算研究[J]. 内蒙古师范大学学报(自然科学汉文版),2015, 44(5):660-666
WULAN T Y, BAO G, WUYUN D J, et al. Hyper-spectral remote sensing estimates of aboveground biomass of grassland [J]. Journal of Inner Mongolia Normal University (Natural Science Edition), 2015, 44(5):660-666
- [28] THOMSON E R, SPIEGEL M P, ALTHUIZEN I H J, et al. Multiscale mapping of plant functional groups and plant traits in the High Arctic using field spectroscopy, UAV imagery and Sentinel-2A data[J]. Environmental Research Letters, 2021, 16(5):055006
- [29] REN H R, ZHOU G S, ZHANG X S. Estimation of green aboveground biomass of desert steppe in Inner Mongolia based on red-edge reflectance curve area method [J]. Biosystems Engineering, 2011, 109(4):385-395
- [30] MUTANGA O, SKIDMORE A K. Red edge shift and biochemical content in grass canopies[J]. ISPRS journal of Photogrammetry and Remote Sensing, 2007, 62(1):34-42

(责任编辑 刘婷婷)