doi:10.6041/j.issn.1000-1298.2025.11.006

融合植被三维结构与光谱特征的草原地上生物量估算模型

王天一[1,2]　路梦源[1]　贺　刚[3]　王　强[4]

(1. 中国农业大学工学院, 北京 100083; 2. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083;
3. 中国农业机械化科学研究院集团有限公司, 北京 100083;
4. 中国农业机械化科学研究院呼和浩特分院有限公司, 呼和浩特 010010)

摘要: 针对温带典型草原地上生物量(Above ground biomass,AGB)精准估算研究中,传统光谱遥感因缺乏三维结构信息导致反演精度受限,而激光雷达等三维数据获取技术成本高昂的问题,以张家口市察北管理区草原为研究区,提出基于消费级深度相机与无人机多光谱技术的融合方法,开展草原 AGB 反演研究。利用深度相机获取样方俯视影像,通过计算每个扫描核的"有效高度×覆盖度"并累加积分,量化植被三维体积,提取表征植被"高度-覆盖度"耦合特征的植被投影体积指数(Vegetation projected volume index,VPVI);结合无人机多光谱影像提取的单波段波反射率及多种植被指数(Vegetation indexs,VIs),经主成分分析(Principal component analysis,PCA)筛选出对生物量敏感的核心光谱特征,进而采用随机森林算法,分别构建基于单一 VPVI、单一 VIs 及 VPVI-VIs 的 AGB 反演模型。对比分析不同模型的性能差异,结果显示:VPVI-VIs 组合模型表现最优,测试集 R^2 为 0.87、RMSE 为 13.77 g/m^2,显著优于单一 VPVI(R^2=0.73)和单一 VIs(R^2=0.77)模型;特征重要性分析显示,VPVI 在组合模型中占比 42%,为核心特征,光化学反射指数(Photochemical reflectance index,PRI)和归一化植被指数(Normalized difference vegetation index,NDVI)合计占比 24%,作为关键补充特征。散点图验证显示,模型在 30~150 g/m^2 区间预测稳定,95%预测带包裹度高。研究证实,VPVI 与 VIs 的融合可有效提升草原 AGB 反演精度,为低成本、高效的草原生物量监测提供技术支撑。

关键词: 草原地上生物量; 估算模型; 植被投影体积指数; 无人机多光谱; 植被三维结构

中图分类号: S127; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0076-08　　**OSID**:

Estimation Model of Grassland above Ground Biomass Integrating Three-dimensional Structure and Spectral Characteristics of Vegetation

WANG Tianyi[1,2]　LU Mengyuan[1]　HE Gang[3]　WANG Qiang[4]

(1. *College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Smart Agricultural System Integration*, *Ministry of Education*, *China Agricultural University*, *Beijing* 100083, *China*
3. *Chinese Academy of Agricultural Mechanization Sciences Group Co.*, *Ltd.*, *Beijing* 100083, *China*
4. *Hohhot Branch of Chinese Academy of Agricultural Mechanization Sciences Co.*, *Ltd.*, *Hohhot* 010010, *China*)

Abstract: Accurate estimation research of above ground biomass (AGB) in temperate typical grasslands was constrained by the limitations of traditional spectral remote sensing, which failed to capture three-dimensional (3D) structural information, while high-precision 3D data acquisition technologies such as LiDAR are often associated with high costs. To address these issues, a fusion method based on consumer-grade depth cameras and UAV multispectral technology was proposed, with the grassland in Chabei Management Zone, Zhangjiakou City, selected as the research area. Top-view images of all quadrats (0.5 m×0.5 m each) were captured by using a ZED2i depth camera. Each quadrat was divided into 25 fine scanning kernels (0.1 m×0.1 m), and the vegetation projected volume index (VPVI) was extracted to characterize the "height-coverage" coupling feature of vegetation. The VPVI was calculated

收稿日期: 2025-08-25　修回日期: 2025-09-10

基金项目: 中国机械工业集团有限公司科研专项(ZDZX2024-49)、财政部和农业农村部:国家现代农业产业技术体系项目(CARS-34-21)、中国农业大学 2115 人才工程资助项目和中央高校基本科研业务费专项资金项目(中国农业大学 2025TC013)

作者简介: 王天一(1990—),男,副教授,博士,主要从事无人机遥感技术和智能草业装备研究,E-mail: tianyi.wang@cau.edu.cn

通信作者: 王强(1980—),男,正高级工程师,主要从事农牧业机械研究,E-mail: wangqiangngd@126.com

by summing the product of effective height (derived from depth data) and green vegetation coverage (obtained via HSV segmentation) across all kernels, thereby quantifying the 3D volume of vegetation in a simplified manner. Meanwhile, single-band reflectances (red, near-infrared) and multiple vegetation indices (VIs, including NDVI, PRI) were extracted from UAV multispectral images. Principal component analysis (PCA) was applied to filter these spectral data, and core features sensitive to AGB were retained. Three AGB inversion models were constructed by using the random forest algorithm: VPVI-only model, VIs-only model, and VPVI − VIs fusion model. The results showed that the fusion model achieved the optimal performance. Its training set exhibited coefficient of determination (R^2) of 0.92 and root mean square error (RMSE) of 8.49 g/m^2, while the test set yielded R^2 of 0.87 and RMSE of 13.77 g/m^2. These results were significantly better than those of the VPVI-only model (test set R^2 = 0.73) and the VIs-only model (test set R^2 = 0.77). Feature importance analysis indicated that VPVI accounted for 42% of the contribution in the fusion model, serving as the core feature, while the combined contribution of PRI and NDVI reached 24%, acting as key supplements. Scatter plot validation demonstrated that stable predictions were achieved in the AGB range of 30 ~ 150 g/m^2, with high coverage rate of the 95% prediction interval. The rsearch result confirmed that the fusion of VPVI and VIs effectively improved the accuracy of grassland AGB inversion, providing a low-cost and efficient technical support for large-scale grassland biomass monitoring.

Key words: grass above ground biomass; estimation model; vegetation projection volume index; UAV multispectral; three dimensional structure of vegetation

0　引言

草地生态功能涵盖碳汇存储、水土保持及生物多样性维持[1]。地上生物量(Above ground biomass, AGB)作为草地生态系统生产力的核心指标,不仅反映植被生长状况,更是连接植物生理过程与生态系统功能的关键纽带,其精准估算对全球气候变化研究、草地资源管理及生态安全评估具有科学意义[2-3]。然而,温带典型草原植被的高度异质性和复杂光谱特性,使得 AGB 的精准估算面临显著挑战。传统光谱遥感技术通过植被指数构建光谱反射与生物量的统计关系,其本质是对单像素光谱进行“点式量化”,难以捕捉植被冠层起伏、群落疏密等结构特征[4-6]。在植被中高覆盖度下,光谱指数易忽略冠层高度起伏,使 AGB 高值区反演偏差大[7];在低覆盖度时,植被与土壤光谱混合,单一指数无法表征空间异质性,混合像元干扰致使精度下降[8]。究其根源,单一光谱参量无法捕捉植被三维形态与植被-土壤空间配置,而多尺度空间结构信息才是反映生物量垂直积累、水平分布差异的核心[9-10]。

为突破局限,国内外学者聚焦整合结构信息提升 AGB 估算精度[11]。目前,主流技术路径有:基于运动恢复结构(Structure from motion, SfM)的被动成像技术[12-13]、基于高分辨率影像的纹理分析算法[14-15],以及以激光雷达(LiDAR)为代表的主动遥感技术[16-17]。文献[18]利用 TLS(Terrestrial laser scanning)与 SfM 构建基于草地冠层三维结构特征的生物量估算模型,TLS 干生物量估算精度(Normalized root mean square error, nRMSE)较 SfM 提升 13.3%,草地特定模型决定系数 R^2(0.72)较全球模型(0.61)提升 18%,证实冠层三维参数可增强异质草地生物量估算准确性;文献[19]利用无人机 RGB - SfM 技术构建草地干物质产量(Dry matter yield, DMY)预测模型,基于冠层高度模型的决定系数 R^2 为 0.81,显著优于单一光谱指数,异质冠层群落的精度提升 17%,凸显冠层三维结构参数的重要作用;文献[20]使用 TLS 获取农牧交错带草地植被结构信息,构建多种 AGB 回归模型(R^2 = 0.73 ~ 0.84),明确冠层覆盖率与植被最低高度为估算草地 AGB 的核心预测因子;文献[21]利用无人机 LiDAR 获取草地点云,结合压缩草层高度(Compressed sward height, CSH)构建 AGB 估算模型,R^2 达 0.89,验证植被三维参数能实现异质草地 AGB 的高精度估算。

综合来看,现有研究达成两点共识:结构信息是突破光谱技术局限的核心要素,SfM(宏观形态)与 LiDAR(微观梯度)均可提升 AGB 估算精度(R^2 普遍提升 0.1 ~ 0.3);关键结构参数具有跨技术一致性,冠层高度、覆盖率参数与 AGB 积累过程稳定关联,为较优预测因子。究其本质,三维结构特征能够表征植被“空间体积积累”,与 AGB 的物理本质形成更直接的关联,这是单一光谱信号难以实现的机制性突破[22]。但技术仍存局限,SfM 提取植被结构信息的精度易受光照影响,LiDAR 成本高、后处理复杂,且植被近地结构参数与空中光谱融合不足。

据此,本文提出一种基于垂直视角深度图像的信息提取方法,通过消费级深度相机(ZED 2i 型)提取植被投影体积指数(Vegetation projected volume

index,VPVI),整合冠层垂直高度与水平投影面积,并将其与无人机多光谱植被指数耦合,构建“光谱-结构”特征融合的 AGB 估算模型,提升草地 AGB 的估算精度。

1 材料与方法

1.1 试验区概况

研究区域选定为张家口市察北管理区内国家牧草产业技术体系实验站(41°48′N,115°01′E,图 1)。该区域属东亚大陆季风气候的温带干旱、半干旱区,地处华北农牧交错带,平均海拔 1 450 m,年均降水量 380 mm,降水集中于 6—8 月,雨热同期。

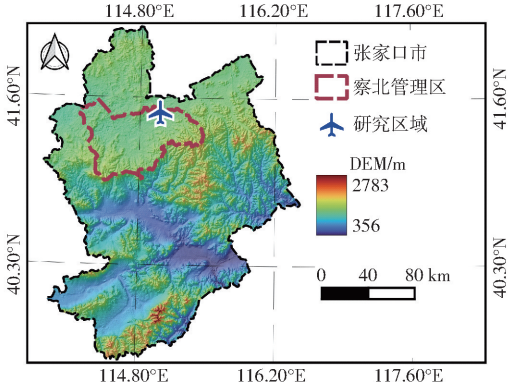


图 1 研究区域概况

Fig. 1 Location of study site

研究区域内人工牧草与天然草原植被混生,形成典型“人工-天然”植被异质性,人工牧草多为紫花苜蓿,天然草原植被以羊草、针茅、锦鸡儿等旱生草本及小灌木群落为主。选定该区域开展研究,既可利用复杂植被类型,验证方法对不同草原植被结构的适配性,也可为北方温带草原区提供可迁移的技术参考。

1.2 试验数据获取及处理

1.2.1 无人机遥感数据采集

采用大疆 Mavic 3 Multispectral 型无人机系统获取研究区域多光谱影像,该系统搭载四波段光学传感器,覆盖 560 nm 绿(Green,G)、650 nm 红(Red,R)、730 nm 红边(Red_Edge,RE)、860 nm 近红外(NIR,N)波段,有效像素为 5.00×10^6。无人机航线飞行参数设定如下:飞行高度为 50 m,航线速度 1.2 m/s,拍照间隔 3 s;航向、旁向重叠率均为 75%,地面分辨率为 3.5 cm/像素。

数据采集时间为 2025 年 6—7 月(植被生长季中后期,AGB 累积、冠层结构及光谱特征差异显著且稳定),采集期内晴朗无云天气,于每日 11:00—13:00(UTC +8)时段内完成航测,此时段太阳高度角 65°~70°,地表阴影干扰相对最小。飞行时相机镜头垂直向下,通过航线规划确保航测范围覆盖整个研究点。研究区域内设定 5 个地面控制点(Ground control points,GCPs),分布于研究区四角及中心,使用无人机装载的 RTK - GPS 模块同步测量 GCPS 的地理坐标,用于后续数据处理的空间定位。

1.2.2 样方布设与地面数据采集

采用系统抽样法在研究区均匀布设 110 个 0.5 m×0.5 m 样方,样方间距 10~15 m,覆盖典型草原(羊草、针茅群落)与荒漠草原(冷蒿、短花针茅群落),植被覆盖度梯度为 40%~90%,地上生物量范围为 20~300 g/m^2。在多光谱影像采集后 24 h 内,以白色 PVC 拼接的方框界定样方边界,使用卓林 P20 型便携式 GNSS 接收机记录样方中心 WGS 84 坐标系经纬度坐标。

深度相机数据采集同步开展,将 ZED 2i 型深度相机固定于拍摄支架,距地面垂直高度 1 m,以垂直向下视角为基准,对每个样方拍摄 3 幅垂直视角的影像,完整覆盖样方框边界,并同步获取 16 位深度图像与 RGB 图像。该相机可拍摄 2 208 像素×1 242 像素深度图像,支持 0.3~20 m 深度测量范围,在 1 m 工作距离下深度精度在 ±1 cm 范围内,满足植被冠层高度与结构分析需求。拍摄时启用固定曝光参数(增益 100,曝光时间 1/1 000 s)与色温白平衡,尽可能削弱光照变化对影像一致性的影响。

完成样方的近地深度图像和 RGB 图像拍摄后,采用齐地刈割法获取样方内全部植被,收纳至牛皮纸袋,2 h 内使用电子天平(精度 0.01 g)称量鲜质量。随后将样品置于 DHG - 9240A 型立式鼓风干燥箱,于 105℃下快速脱水,然后在 75℃烘干至质量恒定,记录干质量并换算为 AGB(单位:g/m^2)。

1.2.3 数据预处理

将无人机采集的多光谱原始影像导入 Agisoft Metashape Professional 2.2.1(Agisoft 有限责任公司,俄罗斯)软件进行对齐拼接,并导入 GCPS 进行图像地理信息和三维畸变矫正,获得研究区域的 4 个单波段和 RGB 正射影像图。在 ENVI 5.6 (Harris Geospatial Solutions 公司,美国)软件中进行单波段正射影像的辐射定标与大气校正,将原始数字量化值(Digital number,DN)转换为表观反射率。接着,将转换后的正射影像导入 QGIS Desktop 3.40.6 (QGIS 协会,瑞士)中,同时导入所有样方的中心点 GPS 坐标,并以每个坐标点为中心创建 0.5 m×0.5 m 正方形矢量边界,通过空间叠合分析验证采样点图像坐标与实际位置的定位偏差,对偏差超过 0.5 m 的点位进行手动校正,并基于正方形矢量边界对所有正射影像图进行裁剪保存。

对获取的样方近距离 RGB 图像和深度图像进行联合预处理，采用 OpenCV－Python（OpenCV 基金会，美国）工具包对 RGB 图像中白色 PVC 样方框内部区域进行检测与分割：首先将图像转换至 HSV 颜色空间，通过设定白色阈值提取掩膜，经形态学闭运算填充孔洞后，基于掩膜检测闭合轮廓，通过面积筛选与最小外接矩形拟合定位方框四角坐标，按坐标裁剪出感兴趣区域（Region of interest，ROI），用于样方盖度信息估算。

在 Matlab R2023a（The MathWorks 公司，美国）中进行深度图像对应区域映射时，利用深度相机内参（焦距、主点坐标）将 RGB 图像中检测到的方框角点转换为深度图像坐标系坐标，基于转换后的坐标从 16 位深度图像中裁剪相同区域，整体处理流程如图 2 所示。

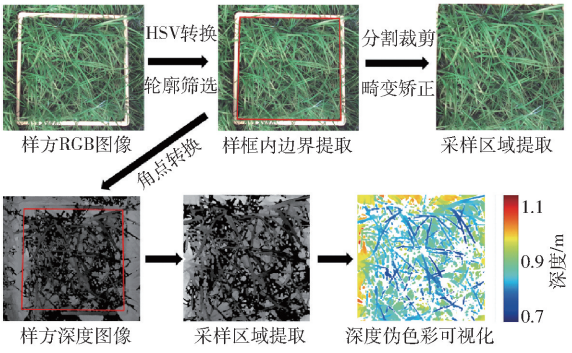


图 2　近地图像预处理过程

Fig. 2　Near-ground image preprocessing process

利用无人机和深度相机的 RGB 图像，对照牧草样本的鲜质量和干质量数据进行逐一检查，识别并剔除与植被覆盖情况明显不符的异常值，最终获得有效样本组，共 100 组。

1.3　模型构建与特征筛选

1.3.1　模型选择与构建

随机森林（Random forest，RF）算法[23]作为一种集成学习方法，能有效处理高维、非线性数据，抗过拟合且稳定性强，适配本研究“光谱-结构”多源特征融合需求。其可自动量化特征重要性，解决多源数据冗余与关键信息筛选难题；对噪声和异常值鲁棒性强，能缓解无人机影像光照干扰、深度图像误差等不确定性，无需预设变量分布，直接捕捉生物量与多源特征的生态关联，故选用 RF 构建 AGB 估算模型。

模型构建采用网格搜索结合蒙特卡罗交叉验证（Monte Carlo cross validation，MCCV）[24]策略，定义超参数搜索空间（树的数量、最大树深度、节点分裂最小样本数、叶子节点最小样本数）并进行 300 次迭代，每次以 85% 训练集、15% 测试集划分，训练集同样以 MCCV 评估模型性能，R^2 最大化为目标筛选最优参数组合。

1.3.2　光谱特征提取与筛选

结合研究区域优势物种、植被盖度及 AGB 分布特征，匹配无人机多光谱传感器波段配置，筛选对植被结构、叶绿素含量及覆盖度敏感的植被指数，筛选原则为：保留核心原始波段基础信息，覆盖植被生长、结构、胁迫等多维度特征，适配不同覆盖度场景与环境干扰校正需求。初步选取的植被指数包括：

归一化植被指数（NDVI），反映植被密度和覆盖度，指示整体生长状况；比值植被指数（RVI）[26]，补充高覆盖区信息，避免 NDVI 饱和；土壤调节植被指数（SAVI）[27]和优化土壤调节植被指数（OSAVI）[28]，通过土壤调节因子削弱低覆盖区土壤干扰；绿度比值指数（GRVI）[29]，敏感反映植被“绿度”，辅助识别叶绿素基础状态；红边归一化植被指数（NDRE）[30]，精细反映叶绿素与冠层变化；光化学反射指数（PRI）[31]，指示光化学效率与胁迫响应；重归一化植被指数（RDVI）[32]，平衡中等覆盖区信号。

综上，8 个 VIs 结合 4 个原始波段共同作为输入变量，在进行 Z-score 标准化后采用主成分分析（Principal component analysis，PCA）[33]进行降维处理。结果显示，前 3 个主成分（PC1－72.2%、PC2－17.5%、PC3－7.0%）累计方差解释率达 96.7%（图 3）。

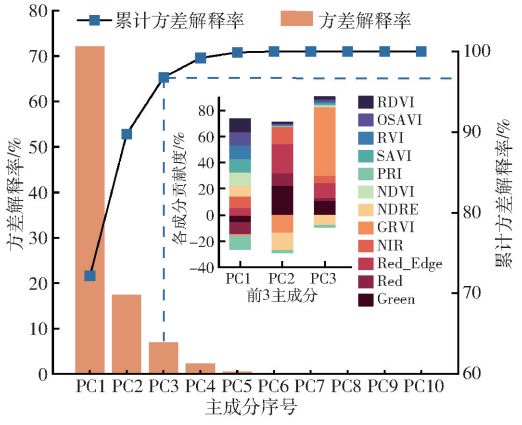


图 3　光谱参数主成分分析

Fig. 3　Principal component analysis of spectral parameters

PC1 中，Red 与 NIR 波段载荷显著，主成分贡献度分别为－0.31 和 0.29，为解析植被结构提供基础；NDVI（0.34）、RVI（0.34）、RDVI（0.34）对植被覆盖度与 AGB 变异贡献突出，且 NDVI 可替代共线性较高的 SAVI、OSAVI；PRI（－0.33）则体现对光化学效率与胁迫响应的关键作用。PC2 中，近红外（0.33）与红光（0.23）仍保持一定载荷，进一步验证其捕捉冠层细节差异的必要性。PC3 主要由 GRVI

主导,但因解释率较低且对 AGB 主导作用有限,不纳入筛选。因此,筛选出对 AGB 估算更精简有效的光谱信息:R、N 波段以及 NDVI、PRI、RVI、RDVI 指数。

1.3.3 深度特征提取

通过耦合植被垂直高度与水平覆盖度的空间投影关系,构建 VPVI,以量化植被三维体积特征。该指数的核心创新在于将植被三维体积进行精细化线性重构,实现对异质草原植被三维结构的近似表征,具体建模逻辑与推导如下:

首先,针对研究区域内植被“高矮混生、覆盖度不均”的异质性,将 0.5 m×0.5 m 样方划分为 25 个 0.1 m×0.1 m 的扫描核,形成精细的空间剖分单元,捕捉植被冠层的局部高度差异。

接着,为精准提取植被自身高度,以整个样方内所有深度数据的 5% ~10% 分位数的均值作为地面基准深度 h_{ground},排除极端低值噪声点,保留真实地面的主体深度,以第 i 个扫描核对应图像区域的平均深度作为 h_i,计算得出第 i 个扫描核内的植被有效高度 $h_{eff,i}$,公式为

$$h_{eff,i} = h_i - h_{ground} \tag{1}$$

同时,为表征植被在水平方向的分布密度,将深度相机同步采集的 RGB 图像转换至 HSV 空间,并设定阈值分割绿色植被区域,计算第 i 个扫描核内绿色植被像素占比面积 w_i(m^2),公式为

$$w_i = an_{g-pix,i} \tag{2}$$

式中 $n_{g-pix,i}$——第 i 个扫描核内绿色植被像素数

a——单像素实际面积

最终,将每个扫描核视为“高度-覆盖度耦合的柱体”,其体积近似为“有效高度×水平覆盖面积”,通过线性累加所有扫描核体积,实现对样方植被三维体积的近似表征,数学表达式为

$$V = \sum_{i}^{n} h_{eff,i} w_i \tag{3}$$

式中 V——样方内植被投影体积指数(VPVI),m^3

基于上述方法,对每个样方拍摄的 3 幅俯视深度图像分别计算单幅影像的 VPVI,实现对样方植被三维结构的模拟(图 4),并通过加和求平均得到样方的最终 VPVI,以此作为多模态融合回归模型的输入变量。

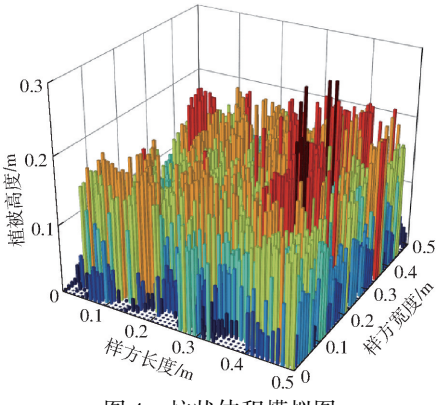


图 4 柱状体积模拟图

Fig. 4 Cylindrical volume simulation diagram

1.3.4 模型评价指标

模型验证采用独立测试集(15%)评估泛化能力,计算指标包括决定系数(R^2)、均方根误差(RMSE)、相对误差(RE),分别用于衡量模型的拟合优度、绝对误差、相对精度,并使用 Lin's 一致性相关系数(Concordance correlation coefficient, CCC)[34]来综合评估预测值与测量值的相关性和一致性。

CCC 的取值范围为[-1,1],测量值与预测值的绝对差值越小且分布趋势越一致时,CCC 越大,因此该指标越接近 1,表明算法的预测精度与一致性表现越优。

2 结果与分析

将 4 个筛选出的 VIs 与 VPVI 一同作为特征输入参数,基于 RF 算法开展 AGB 反演模型的训练与测试。并分别以 VIs、VPVI 以及 VPVI-VIs 作为输入,进行 20 次重复试验,记录并统计相关评估指标的平均值,以分析不同特征组合下模型的性能表现。

2.1 模型性能对比

统计 RF 回归模型在不同特征输入下训练集和测试集的 RMSE、RE、CCC、R^2(表 1)。

表 1 不同数据集下 RF 回归模型评估指标

Tab. 1 Evaluation metrics of RF regression models under different datasets

特征类型	训练集				测试集			
	RMSE/(g·m^{-2})	RE/%	CCC	R^2	RMSE/(g·m^{-2})	RE/%	CCC	R^2
VPVI	12.52	11.94	0.88	0.83	15.91	14.32	0.84	0.73
VIs	11.29	11.61	0.92	0.86	15.41	16.13	0.86	0.77
VPV-VIs	8.49	7.22	0.95	0.92	13.77	12.93	0.93	0.87

在训练集与测试集中,VPVI-VIs 融合特征的表现均显著优于单一特征输入,凸显出强烈的信息协同效应。训练阶段,融合特征的平均 RMSE 为 8.49 g/m^2、RE 为 7.22%、CCC 达 0.95、R^2 为 0.92,

相较单独 VPVI，其 RMSE 和 RE 分别降低 32.0% 和 33.6%，R^2 和 CCC 的提升更为明显；与单独 VIs 相比，RMSE 和 RE 降低 24.8% 和 37.8%，拟合能力与数值一致性优势突出。测试阶段，融合特征的优势持续保持：平均 RMSE 为 13.77 g/m^2、RE 为 12.93%、CCC 为 0.93、R^2 为 0.87，不仅较单独 VPVI 的 RMSE 降低 13.8%、R^2 提升 19.2%，也较单独 VIs 的 RE 降低 19.8%、R^2 提升 13.0%。

融合特征的训练-测试指标稳定性显著优于单一特征：其 CCC 仅下降 0.02，R^2 差值为 0.05，远低于单独 VPVI（CCC 下降 0.04，R^2 差值 0.10）和单独 VIs（CCC 下降 0.06，R^2 差值 0.09）。这一结果证实，VPVI－VIs 融合特征不仅能充分捕捉 AGB 与“光谱-结构”特征的复杂关联，有效削弱预测偏差，还能高度保证预测值与实测值的数值一致性。

2.2　模型特征参数与反演结果分析

最佳反演模型中模型特征参数的相对重要性，对于理解 AGB 反演机制及后续优化模型构建至关重要。图 5 呈现了最佳拟合模型中各特征参数的相对重要性排序，能够揭示植被三维结构与光谱信息在 AGB 反演模型中的作用。

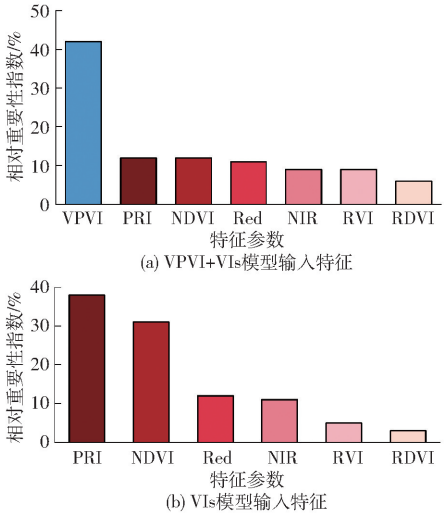


图 5　最佳拟合模型中特征参数相对重要性排序

Fig. 5　Relative importance ranking of feature parameters in the best fitting model

在 VPVI－VIs 组合中，VPVI 以 42% 的相对重要性居于首位，远超其余植被指数。这一结果凸显了植被三维结构信息在 AGB 反演中的核心地位，VPVI 量化的样方内草地植被“高度-覆盖度”耦合特征，能有效弥补传统光谱植被指数对垂直结构与空间体积表征的不足，直接关联植被 AGB 的空间占据能力。在 VIs 中，PRI 和 NDVI 相对重要性指数均为 12%，紧随 VPVI 之后。PRI 对植被光化学效率敏感，能反映光合活性变化，而 NDVI 则与植被覆盖度和叶绿素含量紧密相关，其所映射的植被生理状态与覆盖特征对 AGB 估算同样不可或缺。R、N、RVI 和 RDVI 的重要性相对较低，在该组合模型中对 AGB 反演的贡献相对有限。

在仅包含 VIs 的模型中，PRI 以 38% 的绝对优势成为最重要的特征参数，NDVI 次之，占比 31%。同时，对比两个模型的特征参数重要性分布可发现，在仅含 VIs 的模型里，PRI 和 NDVI 二者重要性占比之和高达 69%，几乎主导了整个模型；而在 VPVI＋VIs 组合模型中，尽管 PRI 和 NDVI 依然重要，但二者占比之和仅为 24%，VPVI 占据了近一半的重要性权重。这意味着当引入 VPVI 后，模型的主导特征从单纯的光谱信息转变为以三维结构信息为主导，光谱信息作为重要补充的模式。

为进一步验证上述特征组合策略的实际效能，基于最佳拟合模型（VPVI－VIs）的测试集结果，通过实测值与预测值的散点分布特征（图 6），直观分析模型的反演精度与误差分布规律。

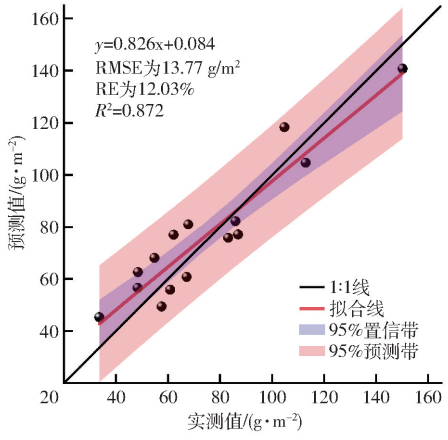


图 6　最佳模型 AGB 实测值和预测值拟合结果

Fig. 6　Fitting results of measured and predicted values of optimal model AGB

在实测值 30～80 g/m^2 的中低 AGB 区间，散点较为集中地分布在 1∶1 线附近，在该区间模型对 AGB 的预测较为精准。在 80～160 g/m^2 的中高 AGB 范围，部分散点出现一定程度偏离 1∶1 线的情况，但大多仍处于 95% 预测带内，离散程度整体较为均匀，在可接受范围内。

3　讨论

本研究中，VPVI－VIs 融合模型的反演精度（测试集 R^2 =0.87）显著优于单一特征模型，证实了光谱-结构特征融合在草原 AGB 估算中的必要性，这一结果印证了多源遥感信息协同增效的普遍认知[35-36]。

从机制上看，VPVI 的核心优势在于其对生物量空间积累本质的表征。草原 AGB 不仅取决于光谱

指数所映射的植被水平覆盖特征,更与植被垂直高度的梯度分布直接相关,即使在覆盖度相同的情况下,植被群落高度较高的区域其生物量也会显著更高。VPVI 通过扫描核的高度与覆盖度乘积积分,将这种垂直与水平方向的耦合关系转化为可量化的体积指标,从而与生物量的物理积累过程形成直接关联。光谱指数中的 PRI 和 NDVI 则通过补充植被生理状态信息,进一步细化了不同物种及不同生长阶段的生物量差异,二者共同形成了结构定基、光谱定质的协同效应。

特征重要性分析显示,VPVI 在融合模型中占比 42%,成为核心特征。这与文献[18-19]提出的结构参数是生物量估算主导因子的结论一致,而本研究进一步证实,即便是通过消费级设备提取的简化结构参数(VPVI),其主导作用依然显著。这一结果提示,对于温带典型草原而言,植被的三维空间占据能力是决定 AGB 差异的首要因素,而非单纯的光谱反射特性[37]。尤其在植被覆盖度中等(40% ~ 70%)的区域,VPVI 对稀疏高株与密集矮株的区分能力远优于光谱指数。

在 VPVI-VIs 模型的光谱特征中,红波段、近红外波段、PRI 和 NDVI 合计占比 44%,其作用主要体现为 PRI 凭借对植被光化学效率的敏感性有效区分绿色活体与枯黄植被[38](二者虽覆盖度相近但生物量差异显著),而 NDVI 则通过对整体覆盖度的稳定表征,在低覆盖区(<40%)弥补 VPVI 因覆盖度较低导致的体积估算误差,同时直接参与对植被叶绿素含量、生物量积累潜力的表征[39]。这种结构主导、光谱补充的特征贡献模式,为草原生物量监测的特征选择提供了明确方向,即优先捕捉三维结构信息,再辅以关键生理光谱指标。

最优的反演模型在 40 ~ 100 g/m^2 区间表现稳定,95% 预测带包裹度高,这与张家口市察北管理区草原优势群落 AGB 的实际分布特征高度匹配。但模型在 AGB 大于 100 g/m^2 的高生物量区域存在一定偏差,可能是由于高生物量区域多为紫花苜蓿等丛生牧草,冠层易出现倒伏或重叠,导致 VPVI 对有效高度的估算偏低,这与深度相机难以穿透密集冠层获取真实地面深度有关。同时,高覆盖度下多数光谱指数进入饱和区间,反射率变化趋缓,无法有效区分生物量的细微差异,从而削弱了光谱特征的补充作用。

4 结论

(1)本研究利用无人机多光谱影像和消费级深度相机数据,提取 VIs 与 VPVI,采用 RF 算法构建草原 AGB 反演模型。结果显示,单一特征模型精度有限(VPVI 模型测试集 R^2 = 0.73,VIs 模型 R^2 = 0.77);而 VPVI-VIs 组合模型性能最优,训练集 R^2 达 0.92、测试集 R^2 达 0.87,且训练-测试指标稳定性显著优于单一特征模型(CCC 下降仅 0.02),验证三维结构与光谱特征的融合可有效提升 AGB 反演精度。

(2)VPVI 在组合模型中以 42% 的相对重要性占据主导,凸显了植被“高度-覆盖度”耦合的三维结构信息对 AGB 反演的核心作用;光谱特征中 PRI 和 NDVI 相对重要性指数分别占比 12%,作为关键补充特征协同捕捉植被生理与覆盖特征。

(3)本研究结果证实,基于深度相机的 VPVI 与无人机多光谱 VIs 的融合策略,突破了传统光谱遥感对植被三维结构的“平面化”量化局限,可实现低成本、高精度的草原 AGB 反演,为草地碳汇动态监测、精准管理及生态保护决策提供可复制的轻量化技术路径。

参 考 文 献

[1] ZENG N, REN X, HE H, et al. Estimating the grassland aboveground biomass in the Three-River Headwater Region of China using machine learning and Bayesian model averaging[J]. Environmental Research Letters, 2021, 16(11):114020.

[2] YAO Y, REN H. Estimation of grassland aboveground biomass in northern China based on topography-climate-remote sensing data[J]. Ecological Indicators, 2024, 165:112230.

[3] LI H, LI F, XIAO J, et al. A machine learning scheme for estimating fine-resolution grassland aboveground biomass over China with Sentinel-1/2 satellite images[J]. Remote Sensing of Environment, 2024, 311: 114317.

[4] ZHAO P, LU D, WANG G, et al. Examining spectral reflectance saturation in landsat imagery and corresponding solutions to improve forest aboveground biomass estimation[J]. Remote Sensing, 2016, 8(6): 496.

[5] ZHAO X, SU Y, HU T, et al. Analysis of UAV lidar information loss and its influence on the estimation accuracy of structural and functional traits in a meadow steppe[J]. Ecological Indicators, 2022, 135: 108515.

[6] ZHANG X, BAO Y, WANG D, et al. Using UAV LiDAR to extract vegetation parameters of Inner Mongolian grassland[J]. Remote Sensing, 2021, 13(4): 656.

[7] MUTANGA O, MASENYAMA A, SIBANDA M. Spectral saturation in the remote sensing of high-density vegetation traits: a systematic review of progress, challenges, and prospects[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 198: 297-309.

[8] FENG S, FAN F. Analyzing the effect of the spectral interference of mixed pixels using hyperspectral imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 1434-1446.

[9] GUIMARÃES-STEINICKE C, WEIGELT A, PROULX R, et al. Biodiversity facets affect community surface temperature via 3D canopy structure in grassland communities[J]. The Journal of Ecology, 2021, 109(5): 1969-1985.

[10] GUIMARÃES-STEINICKE C, WEIGELT A, EBELING A, et al. Diversity effects on canopy structure change throughout a growing season in experimental grassland communities[J]. Remote Sensing, 2022,14(7):1557.
[11] WANG Z, MA Y, ZHANG Y, et al. Review of remote sensing applications in grassland monitoring[J]. Remote Sensing, 2022,14(12):2903.
[12] ENTERKINE J, HOJATIMALEKSHAH A, VERMILLION M, et al. Voxel volumes and biomass: estimating vegetation volume and litter accumulation of exotic annual grasses using automated ultra-high-resolution SfM and advanced classification techniques[J]. Ecology and Evolution, 2025, 15(1): e70883.
[13] OKADA M, BARRAS C, TODA Y, et al. High-throughput phenotyping of soybean biomass: conventional trait estimation and novel latent feature extraction using UAV remote sensing and deep learning models[J]. Plant Phenomics, 2024, 6: 0244.
[14] BUXBAUM N, LIETH J H, EARLES M. Non-destructive plant biomass monitoring with high spatio-temporal resolution via proximal RGB－D imagery and end-to-end deep learning[J]. Frontiers in Plant Science, 2022, 13: 758818.
[15] 张慧春,田啟飞,边黎明,等. 基于多视角图像形态颜色纹理特征融合的生物量获取[J]. 农业机械学报, 2024, 55(10): 295－305.
ZHANG Huichun, TIAN Qifei, BIAN Liming, et al. Plants biomass acquisition based on morphological, color and texture features of multi-view visible images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 295－305. (in Chinese)
[16] 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(2):405.
[17] DU L, PANG Y, WANG Q, et al. A LiDAR biomass index-based approach for tree- and plot-level biomass mapping over forest farms using 3D point clouds[J]. Remote Sensing of Environment, 2023, 290: 113543.
[18] WIJESINGHA J, MOECKEL T, HENSGEN F, et al. Evaluation of 3D point cloud-based models for the prediction of grassland biomass[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 78: 352－359.
[19] GRÜNER E, ASTOR T, WACHENDORF M. Biomass prediction of heterogeneous temperate grasslands using an SfM approach based on uav imaging[J]. Agronomy,2019,9(2):54.
[20] XU K, SU Y, LIU J, et al. Estimation of degraded grassland aboveground biomass using machine learning methods from terrestrial laser scanning data[J]. Ecological Indicators, 2020, 108: 105747.
[21] HÜTT C, ISSELSTEIN J, KOMAINDA M, et al. UAV LiDAR-based grassland biomass estimation for precision livestock management[J]. Journal of Applied Remote Sensing, 2024, 18(1): 17502.
[22] ZHOU L, ZHANG H, BIAN L, et al. Phenotyping of drought-stressed poplar saplings using exemplar-based data generation and leaf-level structural analysis[J]. Plant Phenomics, 2024, 6: 205.
[23] SALMAN H A, KALAKECH A, STEITI A. Random forest algorithm overview[J]. Babylonian Journal of Machine Learning, 2024, 2024: 69－79.
[24] YATES L A, AANDAHL Z, RICHARDS S A, et al. Cross validation for model selection: a review with examples from ecology [J]. Ecological Monographs, 2023, 93(1): e1557.
[25] OTENG-FRIMPONG R, KARIKARI B, SIE E K, et al. Multi-locus genome-wide association studies reveal genomic regions and putative candidate genes associated with leaf spot diseases in African groundnut (*Arachis hypogaea* L.) germplasm[J]. Frontiers in Plant Science, 2022, 13: 1076744.
[26] ZHANG L, ZHAO Y, CHEN C, et al. UAV－LiDAR Integration with sentinel－2 enhances precision in AGB estimation for bamboo forests[J]. Remote Sensing,2024,16(4):705.
[27] NGUYEN H, VU H D, RÖDER A. Estimation of above-ground mangrove biomass using landsat-8 data- derived vegetation indices: a case study in Quang Ninh Province, Vietnam[J]. Forest and Society Online, 2021, 5(2): 506－525.
[28] LIU Y, FENG H, YUE J, et al. Improving potato AGB estimation to mitigate phenological stage impacts through depth features from hyperspectral data[J]. Computers and Electronics in Agriculture, 2024, 219: 108808.
[29] WU Y, ZHAO J, CHEN J, et al. Aboveground biomass mapping and analysis of spatial drivers in the Qinghai－Xizang Plateau permafrost zone: a case study of the Beilu River basin[J]. Plants, 2024, 13(5): 686.
[30] NIU X, CHEN B, SUN W, et al. Estimation of coastal wetland vegetation aboveground biomass by integrating UAV and satellite remote sensing data[J]. Remote Sensing,2024,16(15):2760.
[31] MUNYATI C. Detecting the distribution of grass aboveground biomass on a rangeland using Sentinel－2 MSI vegetation indices [J]. Advances in Space Research, 2022, 69(2): 1130－1145.
[32] 周敏姑,闫云才,高文,等. 基于多光谱遥感和 CNN 的玉米地上生物量估算模型[J]. 农业机械学报, 2024, 55(9): 238－248.
ZHOU Mingu, YANG Yuncai, GAO Wen, et al. Estimating aboveground biomass of maize based on multispectral remote sensing and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 238－248. (in Chinese)
[33] GREENACRE M, GROENEN P J, HASTIE T, et al. Principal component analysis[J]. Nature Reviews Methods Primers, 2022, 2(1): 100.
[34] WADOUX A M, MINASNY B. Some limitations of the concordance correlation coefficient to characterise model accuracy[J]. Ecological Informatics, 2024, 83: 102820.
[35] POLEY L G, MCDERMID G J. A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems[J]. Remote Sensing,2020,12(7):1052.
[36] PRANGA J, BORRA-SERRANO I, APER J, et al. Improving accuracy of herbage yield predictions in perennial ryegrass with UAV-based structural and spectral data fusion and machine learning[J]. Remote Sensing,2021,13(17):3459.
[37] BAZZO C O, KAMALI B, HÜTT C, et al. A review of estimation methods for aboveground biomass in grasslands using UAV [J]. Remote Sensing,2023,15(3):639.
[38] GARBULSKY M F, PEÑUELAS J, GAMON J, et al. The photochemical reflectance index (PRI) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies: a review and meta-analysis[J]. Remote Sensing of Environment, 2011, 115(2): 281－297.
[39] MURO J, LINSTÄDTER A, MAGDON P, et al. Predicting plant biomass and species richness in temperate grasslands across regions, time, and land management with remote sensing and deep learning[J]. Remote Sensing of Environment, 2022, 282: 113262.