doi:10.6041/j.issn.1000-1298.2026.03.013

基于机载激光雷达的水稻株高检测方法与泛化能力研究

龙拥兵[1,2]　陈文瀚[1,2]　刘丹丹[1,2]　李　坤[1,2]　王怡涵[1,2]　郭炜伦[1,2]
陈嘉豪[1,2]　徐振江[3]　肖浏骏[4]　汤　亮[4]　兰玉彬[1,2]

(1.华南农业大学电子工程学院(人工智能学院),广州 510642;2.国家精准农业航空施药技术国际联合研究中心,广州 510642;
3.华南农业大学农业农村部植物新品种测试(广州)分中心,广州 510642;
4.南京农业大学智慧农业学院(人工智能学院),南京 210095)

摘要:株高作为水稻表型分析与生长状态评估的核心参数,其高通量检测对育种与生产意义重大。机载激光雷达凭借其高精度优势,已成为水稻株高检测的研究热点。但现有研究普遍基于单一特征构建线性回归模型,在多品种、多育种材料等复杂应用场景中精度与泛化能力不足。为此,本研究采用多特征融合策略构建水稻株高非线性回归模型,提升估算精度。在广州市增城区与三亚市崖州区分别开展田间试验,采集 5 个品种及 225 份水稻育种材料的株高和激光点云时序数据,构建包含高度百分位数、统计参数和冠层剖面面积的多维度特征体系,利用线性与非线性机器学习算法建立了水稻株高的检测模型。试验表明,多特征非线性预测模型的精度高于线性预测模型,其决定系数(R^2)最高达到 0.969,均方根误差(RMSE)低至 4.73 cm,相较于单特征线性模型(R^2 = 0.905,RMSE 为 8.231 cm),R^2 提升 7.2%,RMSE 降低 42.5%;进一步研究泛化性表明,基于广州增城 5 个品种数据构建的模型泛化能力,显著低于基于三亚崖州 225 份育种材料构建的模型,证实水稻样本多样性可有效提升模型鲁棒性。该研究为水稻株高高通量表型分析提供了高精度、高适用性的通用技术框架。

关键词:机载激光雷达;水稻;株高;机器学习;多特征融合;泛化能力
中图分类号:S127;TP79　　**文献标识码**:A　　**文章编号**:1000-1298(2026)03-0129-11　　**OSID**:

Rice Plant Height Detection Method and Generalization Ability Based on UAV LiDAR

LONG Yongbing[1,2]　CHEN Wenhan[1,2]　LIU Dandan[1,2]　LI Kun[1,2]　WANG Yihan[1,2]　GUO Weilun[1,2]
CHEN Jiahao[1,2]　XU Zhenjiang[3]　XIAO Liujun[4]　TANG Liang[4]　LAN Yubin[1,2]

(1. *College of Electronic Engineering* (*College of Artificial Intelligence*), *South China Agricultural University*, *Guangzhou* 510642, *China*
2. *National Center for International Collaboration Research on Precision Agricultural Aviation Pesticides Spraying Technology*, *Guangzhou* 510642, *China*
3. *Ministry of Agriculture and Rural Affairs Plant Variety Testing* (*Guangzhou*) *Sub-center*, *South China Agricultural University*, *Guangzhou* 510642, *China*
4. *College of Smart Agriculture* (*College of Artificial Intelligence*), *Nanjing Agricultural University*, *Nanjing* 210095, *China*)

Abstract: Rice plant height is a core parameter for phenotypic analysis and growth state assessment, and its high-throughput detection is of significant importance for breeding and production. UAV LiDAR, with its high-precision advantages, has become a research hotspot for rice plant height detection. However, existing studies generally constructed linear regression models based on a single feature, which led to insufficient accuracy and generalization ability in complex application scenarios such as multi-variety and multi-breeding material analysis. Therefore, a multi-feature fusion strategy was adopted to build a nonlinear regression model for rice plant height, aiming to improve estimation accuracy. Field experiments were conducted in Zengcheng, Guangzhou, and Yazhou, Sanya, where plant height and laser point cloud time-series data were collected for five rice varieties and 225 breeding materials. A

收稿日期:2025-09-07　修回日期:2025-11-18
基金项目:农业农村部科技项目和高等学校学科创新引智计划项目(D18019)
作者简介:龙拥兵(1979—),男,教授,博士,主要从事作物表型研究,E-mail:yongbinglong@scau.edu.cn
通信作者:兰玉彬(1961—),男,教授,博士,主要从事精准农业航空研究,E-mail:ylan@scau.edu.cn

multi-dimensional feature system, including height percentiles, statistical parameters, and canopy profile area, was constructed. Linear and nonlinear machine learning algorithms were used to establish the detection model for rice plant height. The results showed that the accuracy of the multi-feature nonlinear prediction model was higher than that of the linear prediction model, with the highest coefficient of determination (R^2) reaching 0.969 and the root mean square error (RMSE) as low as 4.73 cm. Compared with the single-feature linear model (R^2 = 0.905, RMSE was 8.231 cm), the R^2 was increased by 7.2% and RMSE was decreased by 42.5%. Further studies on generalization ability indicated that the model built using data from the five varieties in Zengcheng, Guangzhou, showed significantly lower generalization ability compared with the model constructed from the 225 breeding materials in Yazhou, Sanya, confirming that the diversity of rice samples can effectively improve model robustness. The research result can provide a high-precision and highly applicable general technical framework for high-throughput phenotypic analysis of rice plant height.

Key words: UAV LiDAR; rice; plant height; machine learning; multi-feature fusion; generalization ability

0 引言

水稻作为全球半数人口的主粮作物,其株高是反映生长发育过程的核心表型指标之一,且其调控机制与作物生产力及抗逆性密切关联。一方面,适宜的株高可优化冠层光照分布,提升光合效率,直接影响生物量积累与最终产量;另一方面,株高过大易导致茎秆机械强度不足,增加倒伏风险,而过低则可能因生物量积累受限降低产量潜力[1]。因此,高通量、无损、精准地获取水稻全生育期株高动态信息,不仅是水稻长势精准监测的关键,更能为水肥调控、抗倒伏育种筛选等后续田间管理决策提供核心数据支撑[2]。传统人工测量方法虽能获取单点高精准株高数据,但存在测量效率低、无法大尺度应用等局限性,难以支撑现代精准农业对株高动态的高通量表型分析需求[3]。

无人机遥感凭借其操作灵活、时空分辨率高、监测效率突出及全程无损等优势,已成为突破传统测量瓶颈、推动农业精准监测升级的核心技术手段[4]。然而,当前无人机遥感技术在水稻株高反演中仍存在明显技术短板,难以兼顾精度与效率。可见光摄影测量仍是当前应用最广泛的水稻株高反演方法[5],但该技术本质依赖冠层表面纹理与立体匹配生成数字表面模型(Digital surface model, DSM),受冠层穿透能力不足及光照条件敏感性影响,其反演精度较低[6];地面激光扫描仪(Terrestrial laser scanning, TLS)虽能通过高密度激光点云(Light detection and ranging, LiDAR)生成厘米级精度的三维冠层模型,精准提取作物株高[7],但该技术依赖人工布设地面站点,作业效率极低,难以实现大面积、同步化的株高监测。相比之下,机载 LiDAR 具备俯视多回波穿透能力与高效作业特性,为大田尺度水稻株高的高通量、高精度监测提供了可行的技术方案。

当前,基于机载 LiDAR 的株高反演已广泛应用于甜菜[8]、玉米[9]和冬小麦[10]等作物中,其技术有效性与适用性已得到验证[7,11-12]。在水稻领域,THI 等[7]以单一水稻品种为研究对象,基于 LiDAR 高度百分位特征确定了水稻顶部位置和底部位置,进一步计算相对垂直距离来估计株高(R^2 = 0.91),从而完全避免了传统方法中对地表检测的依赖;TILLY 等[11]以 3 个水稻品种为研究对象,开发了基于地面激光扫描的多时相作物表面模型,以 1 cm 分辨率点云生成水稻株高地图,并建立株高-生物量回归模型(R^2 = 0.86),成功应用于大田生物量估算;JING 等[12]以单一品种,提出了一种基于 LiDAR 点云数据的非破坏性检测方法,通过优化百分位分析精确估计水稻株高,并基于高度与叶面积指数(LAI)的强相关性建立回归模型(R^2 = 0.77)。

上述研究虽已证实 LiDAR 在水稻表型分析与株高反演中的应用潜力,然而研究对象多局限于少量水稻品种或者育种材料。在实际育种过程中,往往需同时处理数百份甚至数千份水稻育种材料,且不同材料在株型结构、叶片形态上存在显著差异,这使得现有模型在多品种应用场景下的泛化能力显著下降。例如,不同水稻品种和育种材料的叶片披散度、叶位分布、穗型结构等存在明显差异。当株型为直立型时,LiDAR 能稳定扫描到冠层顶点,从而实现高度百分位数与最大值等特征对水稻株高的高精度表征;而当冠层较为松散或叶片弯曲下垂时,顶部反射点呈随机分布,导致高度百分位数与最大值等特征对水稻株高的表征能力下降。这些由冠层形态引起的激光点云分布差异,降低了单特征模型在多品种和育种材料条件下的泛化能力。

针对上述问题，本研究选取 5 个水稻品种及 225 份遗传背景多样的水稻育种材料作为研究对象，分别在广州市增城区与三亚市崖州区开展田间试验，利用机载 LiDAR 采集水稻多生育期冠层三维点云数据。建立包含高度百分位数、冠层剖面面积及点云统计参数的多维特征体系，结合非线性模型以刻画特征与株高之间的复杂关系，进而构建多特征融合的株高反演模型。系统分析水稻冠层结构差异对 LiDAR 特征的影响，以提高株高反演模型的精度及其在多品种、多育种材料条件下的泛化能力。

1　材料与方法

本研究包括数据获取、数据处理与特征提取、数据建模与分析环节，技术流程如图 1 所示。

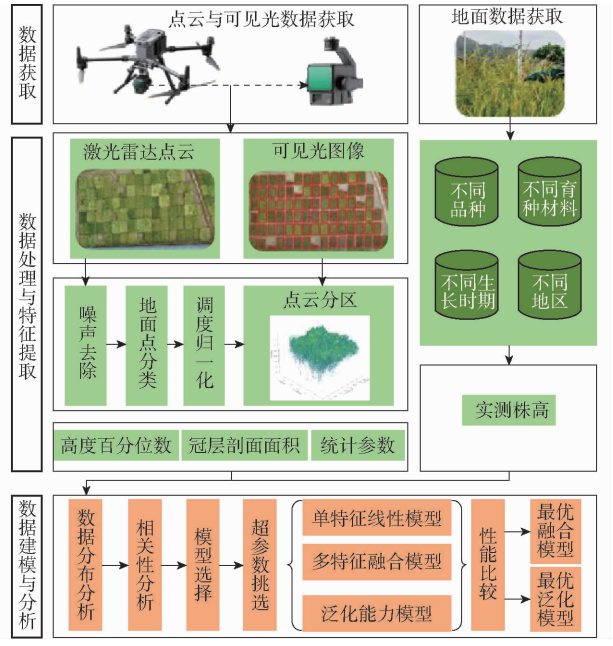

图 1　技术流程

Fig. 1　Technique process

1.1　数据采集

本研究于 2024 年 9—11 月和 2025 年 2—4 月分别在广州市增城区（23°14′47″N，113°38′43″E）和三亚市崖州区（18°21′32.9″N，109°10′2.5″E）开展独立的田间试验。其中，广州市增城区试验种植美香占 2 号、华航香银针、象牙香占、南晶香占、美巴香占 5 个水稻品种，每个品种设置 3 个重复组，并设置 4 个施氮梯度，总计 60 个试验小区；三亚市崖州区试验种植 225 份水稻育种材料（包括红米散单 1 号、红矮糯、台中糯等），每个育种材料对应 1 个独立小区。两个地区水稻实际株高数据和点云数据的采集时间相同，如表 1 所示。

1.1.1　地面数据采集

采用人工测量方式获取水稻实测株高。通过塔尺测量自然状态下水稻基部土壤表面地上位置至水稻最顶端的垂直距离，每个采样区内选取 3 穴有代表性的水稻，其位置与点云分区严格匹配，将 3 穴水稻的株高均值作为该采样区内水稻的实测株高[13]。

表 1　水稻采集时间及对应生长阶段

Tab. 1　Collection time of rice and corresponding growth stages

地点	采集日期	对应水稻生长阶段	数据量（含重复组）
增城区	2024 年 9 月 3 日	分蘖期	90
	2024 年 9 月 28 日	拔节/孕穗期	90
	2024 年 10 月 17 日	抽穗期	20
	2024 年 11 月 1 日	灌浆期	20
	2024 年 11 月 30 日	成熟期	20
崖州区	2025 年 2 月 18 日	拔节/孕穗/抽穗/灌浆期	227
	2025 年 4 月 2 日	孕穗/抽穗/灌浆期	225

1.1.2　遥感数据采集

使用 DJI Matrice 350 RTK 无人机搭载 DJI Zenmuse L2 LiDAR 激光雷达（波长 905 nm，点频 2.4×10^5 点/s）采集水稻冠层三维点云数据，该无人机搭载时间同步系统与高级 RTK 模块，可提供厘米级测量精度与精确的位置信息。同时，DJI Zenmuse L2 集成 LiDAR 模块与测绘相机模块，可同步获取点云与图像数据。在增城区试验中，无人机飞行高度设为 12 m；崖州区试验因受障碍物限制，无人机飞行高度调整为 20 m，两地试验 LiDAR 扫描角度范围为 ±46°，飞行旁向重叠率为 70%[14]。采集的原始数据可重建为 LAS 格式点云文件与 TIF 格式 RGB 图像，后续导入 DJI Terra 软件完成 LiDAR 点云重建与 RGB 影像拼接处理。

1.2　数据处理

1.2.1　噪声去除

经 DJI Terra 软件重建后的激光点云数据采用 WGS84 UTM 坐标系，数据采集过程中，激光点云可能接触低空飞行物（如昆虫等）或因仪器自身系统误差产生噪点，此类噪点会干扰后续数据处理，因此本研究采用基于密度的空间聚类算法去除点云噪声[15]。

1.2.2　点云滤波与高度归一化

为获取地物三维信息，需对去噪后的点云数据进行地面点与非地面点分离，该过程称为点云滤波（又称地面点分类）[16]。本文采用渐进加密不规则三角网滤波（Progressive TIN densification，PTD）算法来实现地面点分类[17]，进一步利用地面点构建数字高程模型（Digital elevation model，DEM），将原始点云的高程值减去该点所在位置的 DEM 高程值，得到归一化后的点云[18]。具体计算公式为

$$Z_{\text{normalized}} = Z_{\text{point}} - Z_{\text{DEM}} \tag{1}$$

式中 $Z_{normalized}$——归一化后点云高程值

Z_{point}——原始点云高程值

Z_{DEM}——数字高程模型高程值

1.2.3 分区裁剪

Zenmuse L2 采集到的图像文件经 DJI Terra 处理拼接后,生成正射影像图(Digital orthophoto map, DOM),且 DOM 与 WGS84 UTM 坐标系进行严格配准;进一步使用 QGIS 结合 DOM,利用 QGIS 编辑工具绘制各研究区域的面矢量文件,利用该面矢量文件对点云进行裁剪,得到每个研究小区的独立点云文件,用于后续特征提取和模型预测。

1.2.4 激光点云特征提取

采用 Python 开源库 Laspy 提取水稻激光点云特征,该库可高效读写与操作 LiDAR 点云数据[19]。根据激光点云特性,将点云特征分为 3 类,分别为高度百分位数特征(反映作物冠层高度信息)、冠层剖面面积特征(量化顶部冠层体积/结构复杂度)和统计参数特征(反映冠层特征统计特性),具体特征体系如表 2 所示。

表 2 用于水稻株高反演的多维度特征体系

Tab. 2 Multi-dimensional feature system for rice plant height inversion

特征类型	特征名称	特征描述	计算公式
高度百分位数	H_{P90}、H_{P95}	冠层顶部高度信息	$H_P = \mathrm{percentile}(H_i, P)$
冠层剖面面积	$H_{PA90-95}$、$H_{PA95-99}$	冠层结构复杂度	$H_{PA} = \sum_{i=1}^{n-1} \frac{H_{Pi} - H_{P(i-1)}}{2}$
统计参数	H_{max}	冠层最高高度	$H_{max} = \max(H_i)$
	H_{mean}	冠层主体高度	$H_{mean} = \frac{1}{n}\sum_{i=1}^{n} H_i$
	H_{sd}	冠层高度离散程度	$H_{sd} = \sqrt{\frac{\sum_{i=1}^{n}(H_i - H_{mean})^2}{n-1}}$
	H_{cv}	高度相对离散程度	$H_{cv} = \frac{H_{sd}}{H_{mean}}$
	H_{ske}	高度分布对称性	$H_{ske} = \frac{\frac{1}{n-1}\sum_{i=1}^{n}(H_i - H_{mean})^3}{\sigma^3}$
	H_{crr}	冠层高度分布均匀性	$H_{crr} = \frac{H_{mean}}{H_{max}}$
	H_{med}	冠层高度分布中心	$H_{med} = \mathrm{med}(H_i)$

注:H_i 表示点云高度,P 表示 0 ~ 100 之间的数值,用来指定要计算的百分位位置。

由于已经进行了高度归一化处理,特征体系中最小高度(H_{min})默认为 0。各特征具体说明如下:

(1)高度百分位数(H_P)表示群体中有多少比例的点云高度低于或等于该特定值。例如,第 95 百分位数表示该区域内约 95% 的点云高度低于该值。本研究选取第 95 百分位数(H_{P95})和第 90 百分位数(H_{P90})两个特征。

(2)冠层剖面面积(Height canopy profile area, H_{PA})。水稻生长形态导致其在不同高度范围的点云分布存在差异,引入 H_{PA} 可量化该差异。冠层剖面面积反映冠层垂直截面的空间占据规模[20],可表征冠层的垂直结构差异。其中,H_{Pi} 为第 i 百分位数,n 为垂直方向的分层数量,本研究按 1 cm 间隔对冠层高度进行分层,累计计算 90% ~95% 与 95% ~99% 高度区间的剖面面积,分别记为 $H_{PA90-95}$ 和 $H_{PA95-99}$。

(3)统计参数包括区域内点云最大值(H_{max})、平均值(H_{mean})、标准差(H_{sd})、变异系数(H_{cv})、偏度(H_{ske})、起伏比(H_{crr})及中位数(H_{med}),用于分析冠层点云的统计特性,在一定程度上反映激光点云的结构特征[21]。

1.3 算法选择与评估指标

1.3.1 算法选择

本研究选择了多种机器学习算法建立水稻株高回归模型:线性回归(Linear regression, LR)[22]、XGBoost(XGB)[23]、极端随机树(Extra tree, ET)[24]和核岭回归(Kernal ridge regression, KRR)[25]。除 LR 不需要超参数以外,其他模型均采用网格搜索法来优化超参数[26]。所有算法均用 Python 实现。

为了提高株高反演模型的泛化能力,采用了多品种/育种材料数据集、多特征融合以及非线性回归相结合的建模策略。在数据集构建方面,采用增城区 5 个水稻品种与崖州区 225 份育种材料的激光点云和株高数据构建混合数据集,使训练集涵盖从矮秆到高秆、从紧凑型到披散型等不同株型结构的品种和育种材料。在特征选取方面,结合高度百分位数、统计参数以及冠层剖面面积 3 类特征进行融合,以捕捉不同品种和育种材料之间的冠层结构差异,克服单一特征的不足。在模型选择方面,采用 KRR 与 XGB 等非线性算法来学习“LiDAR 多维特征-株高”之间的关联规律,提高模型处理冠层结构差异导致精度下降等问题的能力。

1.3.2 评估指标

利用决定系数(R^2)、均方根误差(RMSE)和残差预测偏差(RPD)3 个指标来评估株高估测模型的精度。R^2 越接近 1,表明方程的自变量对株高的解释能力越强,同时与之对应模型的 RMSE 越小,观测值与真实值之间的偏差越小,表示对株高的估测精度越高。RPD 小于等于 2.4 表示预测模型不可靠,RPD 大于 2.4、小于等于 3 表示预测模型可用作近

似估计，RPD 大于 3 表示模型可用于预测[27]。

2　结果与分析

2.1　数据统计与相关性

本试验共采集 692 份水稻实测株高数据，其中广州市增城区数据 240 份，三亚市崖州区数据 452 份。利用小提琴图、箱线图及散点图（图 2a）分析可知，两地实测株高分布存在显著差异，具体如下：

（1）增城区：株高主要集中于 60 ~ 100 cm，中位数低于 80 cm，最大值不超过 140 cm，且数据离散性较高（箱体长度较长）。

（2）崖州区：株高主要分布在 70 ~ 110 cm，中位数高于 80 cm，最大值达 160 cm，高值样本分布更密集，体现 225 份育种材料的多样性。

（3）混合数据集（增城区 + 崖州区）：株高覆盖 40 ~ 160 cm，涵盖矮秆（ <60 cm）与高秆（ >140 cm）极端样本，主要集中于 60 ~ 110 cm，中位数高于 80 cm，其变异幅度显著大于单一地区数据集，可更严格地检验模型对不同株高区间（尤其是极端值）的预测能力。

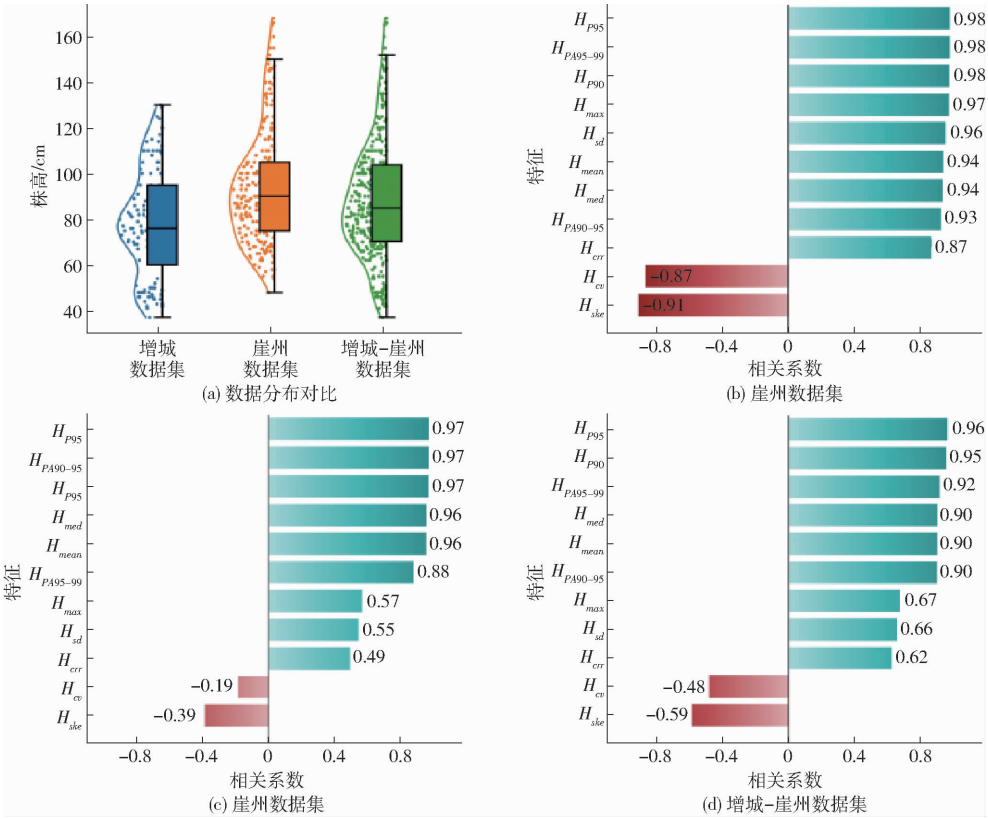

图 2　增城区与崖州区实测株高分布和不同数据集高度参数相关系数条形图

Fig. 2　Distribution of measured plant heights in Zengcheng and Yazhou and bar chart showing correlation coefficients of height parameters among different data sets

使用 Pearson 相关性量化点云特征与株高的关系[28]，结果如图 2 所示。对于增城、崖州以及增城-崖州混合数据集，H_{P95}、H_{P90}、$H_{PA90-95}$、$H_{PA95-99}$、H_{mean} 和 H_{med} 与水稻株高之间均具有高相关性，且相关系数均高于 0.88，这是因为这些 LiDAR 特征直接反映冠层高度信息，与株高物理定义契合。尽管增城和崖州两个地区种植水稻品种和育种材料具有较大差异性，这 6 个特征在两个地区的数据集中，均具有最高的相关性，表明这些 LiDAR 特征与株高之间的相关性受品种的影响较小，可构建跨区域、跨品种的株高预测模型。

另一方面，高度百分位数（H_{P95}、H_{P90}）、冠层剖面面积（$H_{PA95-99}$、$H_{PA90-95}$）及统计参数（H_{mean}、H_{med}）与株高之间均具有较高的相关系数，可以形成互补特征集，覆盖株高的多维表型信息。总之，两数据集特征相关的一致性有助于建立跨数据集适用的多特征融合预测模型。

另外，崖州数据集中，H_{max}、H_{sd}、H_{crr} 等统计特征与水稻株高之间的相关性较低，这主要归因于该数据集内 225 份育种材料具有的高度遗传背景和表型多样性。不同育种材料植株在叶片披散程度、叶倾角、株高差异和穗型结构等方面表现出明显变异。这种冠层结构的高度异质性导致激光点云在空间和垂直方向上分布差异较大，进而削弱了这些统计特征与水稻株高之间的相关性。

以 H_{max} 为例，崖州数据集中复杂的冠层结构使

得激光雷达捕获到真实冠层顶点(叶尖或穗顶)的概率在不同小区间极不稳定,LiDAR 的最高采样点变成了一个随机变量,降低其与株高之间的相关性。相反,增城数据集仅包含 5 个水稻品种,其冠层结构更为均一,对激光点云的反射具有较高的一致性,LiDAR 的最高采样点(H_{max})总能稳定地代表真实的植株高度,因此 H_{max} 与水稻株高的相关性相对较高。

综上,增城-崖州混合数据集中 H_{P95}、H_{P90}、$H_{PA90-95}$、$H_{PA95-99}$、H_{mean} 和 H_{med} 等 LiDAR 特征与水稻株高具有高相关性,同时数据集中水稻品种/育种材料具有多样性,为后续株高回归模型的构建提供了坚实的理论与数据支撑。

2.2 基于单特征的高度回归模型

基于增城区 5 个品种和崖州区 225 份育种材料的所有试验数据组合成混合数据集,构建水稻株高单特征线性回归模型,重点分析测试集决定系数 $R_p^2>0.8$ 的模型性能,如表 3 和图 3 所示。模型训练过程中,采用随机抽样法划分数据集,其中 80% 的数据用于模型训练和多折交叉验证,20% 的数据用于模型测试。

表 3 单特征线性回归结果

Tab. 3 Results of single-feature linear regression

特征	R_c^2	RMSEc/cm	R_p^2	RMSEp/cm	RPD
H_{P95}	0.932	6.723	0.905	8.231	3.250
H_{P90}	0.915	7.503	0.897	8.593	3.113
$H_{PA95-99}$	0.823	9.043	0.886	10.860	2.958
$H_{PA90-95}$	0.807	11.314	0.814	11.529	2.320
H_{med}	0.815	11.097	0.808	11.721	2.282
H_{mean}	0.814	11.107	0.803	11.876	2.252

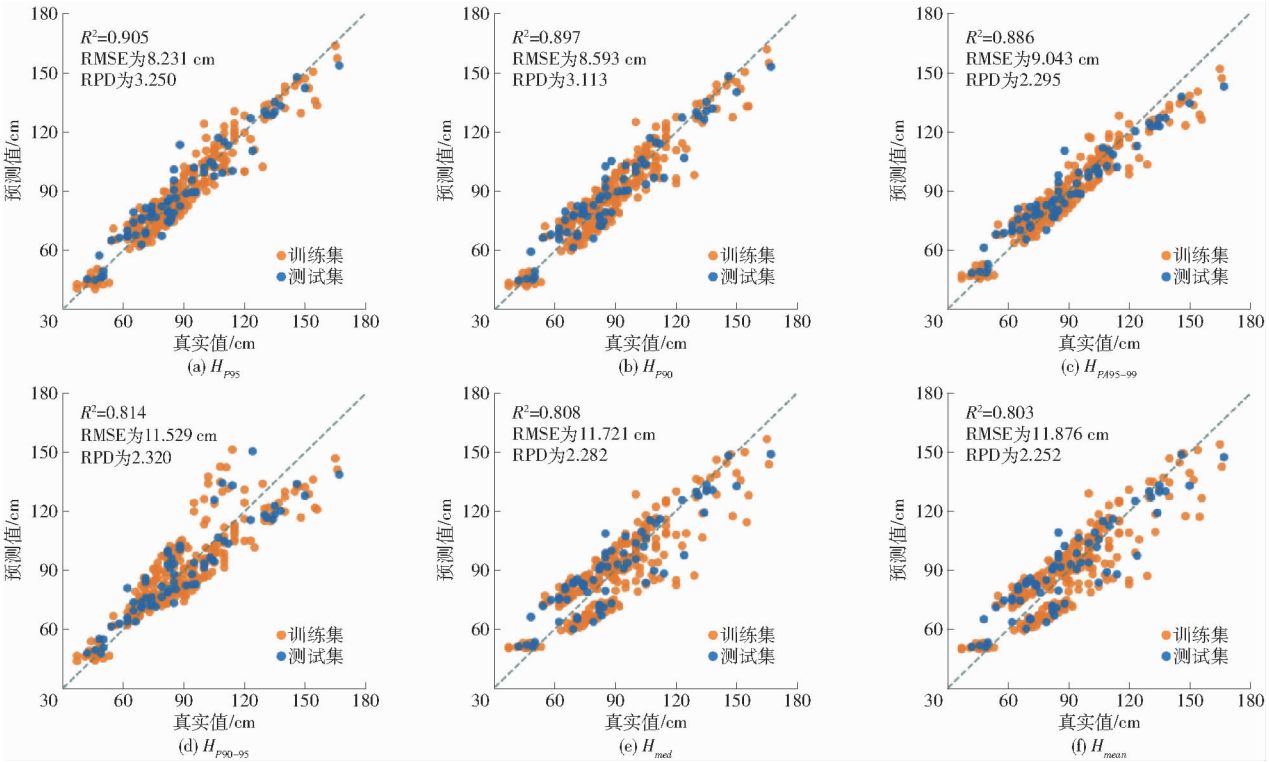

图 3 单特征线性回归模型散点图

Fig. 3 Scatter plots of single-feature linear regression model

结果显示,高度百分位数类特征表现最优,其中 H_{P95} 对应的模型精度最高($R_p^2=0.905$,RMSEp 为 8.231 cm),H_{P90} 次之($R_p^2=0.897$,RMSEp 为 8.593 cm),二者均显著优于冠层剖面面积特征 $H_{PA95-99}$($R_p^2=0.886$,RMSEp 为 10.86 cm)与统计参数特征 H_{med}($R_p^2=0.808$,RMSEp 为 11.72 cm)。这主要是因为 H_{P95} 与 H_{P90} 更加契合水稻株高的物理定义,可精准捕捉水稻冠层顶部关键高度信息,二者与株高的关联具有明确物理对应性,使得线性回归可直接捕捉特征与株高的映射关系,这也与相关性分析中二者与实测株高的高相关系数(H_{P95} 为 0.96、H_{P90} 为 0.95)高度一致。

进一步分析特征性能差异的内在机理可知,模型精度与特征-株高的物理关联性直接相关。高度百分位数(H_{P95}/H_{P90})类特征因直接对应冠层上边界关键高度,与株高的物理定义高度统一,受冠层结构干扰小,故能实现高精度估测;而 $H_{PA95-99}$(相关系数 0.92)与 H_{med}(相关系数约 0.90)对应的模型精度相对较低,是因其分别受冠层剖面面积分布复杂性、统计参数局限性的影响,无法直接建立与株高的物

理映射。此外，整体趋势显示，模型 RMSE 随特征-株高相关系数增大而降低，这表明特征-株高物理关联越强，估测误差越小。同时也表明单特征难以覆盖水稻株型多样性带来的表型差异，后续将通过多特征融合弥补单特征物理表征的局限性，以提升模型泛化性能。

2.3　基于多特征融合的高度回归模型

为了进一步提高株高检测精度，本研究从相关系数较高的高度百分位数（H_{P95}、H_{P90}）、冠层剖面面积（$H_{PA90-95}$、$H_{PA95-99}$）及统计参数（H_{mean}、H_{med}）3 类特征中，每类各选一个特征构建多特征融合回归模型，共形成 2×2×2=8 种特征组合。针对每个特征组合，分别采用 LR、XGB、ET、KRR 算法建模，共建立 32 个株高回归模型。通过对比模型精度，筛选最优特征组合与算法，结果如表 4 及图 4a～4d 所示。

从所有特征组合与模型的表现来看，以 H_{P95}、H_{med}和 $H_{PA90-95}$为特征组合的 KRR 模型具有最高水稻株高估算精度，R_p^2 达到 0.969，RMSEp 为 4.730 cm，RPD 为 5.655，预测能力最好。与 KRR 模型相比，LR 模型、XGB 模型和 ET 模型的 R_p^2 分别降低 0.038、0.023 和 0.02，而 RMSEp 则分别提高 48.6%、31.2% 和 27.4%，表明该特征组合下非线性 KRR 模型性能最优，这同时也证实水稻株高与特征之间存在非线性关系。

表 4　不同特征模型精度对比

Tab.4　Comparison of accuracy of different feature models

高度百分位数	统计参数	冠层剖面面积	模型	R_p^2	RMSEp/cm	RPD
H_{P95}	H_{med}	$H_{PA90-95}$	KRR	0.969	4.730	5.655
H_{P95}	H_{med}	$H_{PA90-95}$	ET	0.949	6.028	4.437
H_{P95}	H_{med}	$H_{PA90-95}$	LR	0.931	7.030	3.805
H_{P95}	H_{med}	$H_{PA90-95}$	XGB	0.946	6.204	4.310
H_{P95}		$H_{PA90-95}$	KRR	0.945	6.291	4.251
	H_{med}	$H_{PA90-95}$	KRR	0.954	5.718	4.678
H_{P95}	H_{med}		KRR	0.957	5.574	4.799
H_{P95}			KRR	0.909	8.051	3.322
	H_{med}		KRR	0.834	10.898	2.450
		$H_{PA90-95}$	KRR	0.824	11.222	2.383

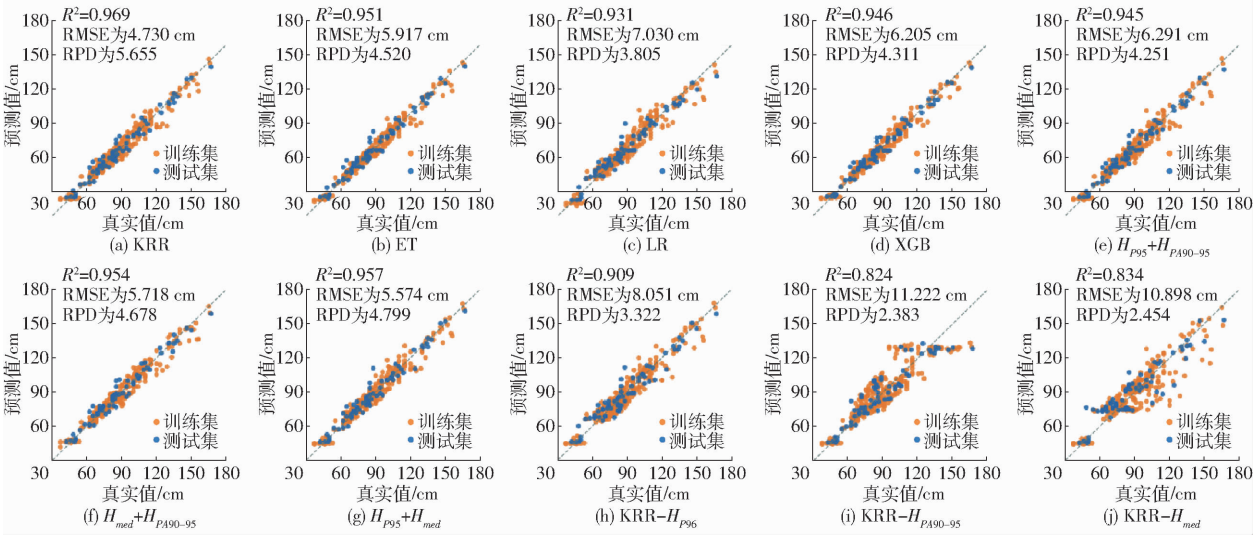

图 4　多特征融合回归模型散点图

Fig.4　Scatter plots of multi-feature fusion regression model

为分析多特征融合模型的优势，建立了基于单特征和双特征的 KRR 水稻株高回归模型，结果如表 4 及图 4e～4f 所示。经对比后得到如下结论：①单一特征回归结果显示，基于 H_{P95}的单特征 KRR 模型性能最优（R_p^2=0.909、RMSEp 为 8.051 cm、RPD 为 3.322），其性能略高于线性模型（R_p^2=0.905，RMSEp 为 8.231 cm，RPD 为 3.250），进一步证明了非线性模型的优势。②基于 H_{P95}、H_{med}和 $H_{PA90-95}$的 3 个特征融合的 KRR 模型，其模型整体性能（R_p^2=0.969，RMSEp 为 4.730 cm、RPD 为 5.655）明显优于单特征和两特征融合时的模型性能。对于双特征融合（H_{P95}+H_{med}组合、H_{med}+$H_{PA90-95}$组合和 H_{P95}+$H_{PA90-95}$组合），尽管模型 R_p^2（0.945～0.957）接近三特征融合模型，但其 RMSEp 和 RPD 表现明显劣势。

上述研究结果表明，高度百分位数、冠层剖面面积和统计参数 3 类特征具有互补性。3 个维度特征的协同作用，结合 KRR 非线性机器学习算法的拟合能力，能显著提升模型精度，为高精度株高反演提供技术方案。

2.4　模型泛化能力

为研究模型的跨数据集（不同品种/育种材料）泛化能力，按试验地区将数据集拆分为增城数据集、

崖州数据集及增城-崖州混合数据集。基于 H_{P95}、$H_{PA90-95}$与 H_{med}的最优特征组合，重新训练非线性模型（选取表现突出的 KRR 与 XGB 模型进行对比分析），系统评估模型在不同地区数据集的泛化性能，具体试验结果如表 5 及图 5 所示。

表 5 模型泛化性能

Tab. 5 Model generalization performance

训练集地区	模型	增城测试集			崖州测试集		
		R_p^2	RMSEp/cm	RPD	R_p^2	RMSEp/cm	RPD
增城	XGB	0.954	5.285	4.684	0.740	12.952	1.963
	KRR	0.936	6.252	3.960	0.558	16.905	1.504
崖州	XGB	0.894	7.698	3.070	0.927	5.348	3.708
	KRR	0.654	13.897	1.701	0.929	5.296	3.744
增城+崖州	XGB	0.943	5.891	4.202	0.927	5.371	3.692
	KRR	0.917	5.725	3.454	0.745	12.499	1.981

2.4.1 不同模型泛化能力分析

以单一地区数据为训练集构建的株高回归模型中，KRR 模型的跨数据集泛化能力显著较弱。以增城数据为训练集时，KRR 模型在本地（增城）测试集上表现优异，R_p^2 达 0.936、RMSEp 为 6.252 cm、RPD 为 3.960；但迁移至崖州测试集后，精度大幅衰减，R_p^2 降至 0.558（较本地降低 40.1%），RMSEp 升至 16.905 cm、RPD 降至 1.504，模型适用性明显下降。以崖州数据为训练集时，KRR 模型在本地测试集上 R_p^2 = 0.928、RMSEp 为 5.339 cm、RPD 为 3.714，而在增城测试集上 R_p^2 仅为 0.654（较本地降低 29.6%），RMSEp 增至 13.897 cm、RPD 降至 1.701，仍存在显著的跨数据集精度损失。

相比之下，XGB 模型展现出更优的泛化性能。以增城数据为训练集时，XGB 模型在本地测试集上 R_p^2 = 0.943、RMSEp 为 5.926 cm、RPD 为 4.178，迁移至崖州测试集后，R_p^2 降至 0.740（仅降低 21.5%），RMSEp 为 12.952 cm、RPD 为 1.963，精度下降幅度仅为 KRR 模型的 53.6%；以崖州数据为训练集时，XGB 模型在本地测试集上 R_p^2 = 0.927、RMSEp 为 5.348 cm、RPD 为 3.708，而在增城数据测试集上 R_p^2 仍保持 0.894（仅降低 3.6%），RMSEp 为 7.698 cm、RPD 为 3.070，跨数据集泛化性能显著优于 KRR 模型。

2.4.2 不同数据集泛化能力分析

不同地区训练集对模型泛化能力的影响存在明

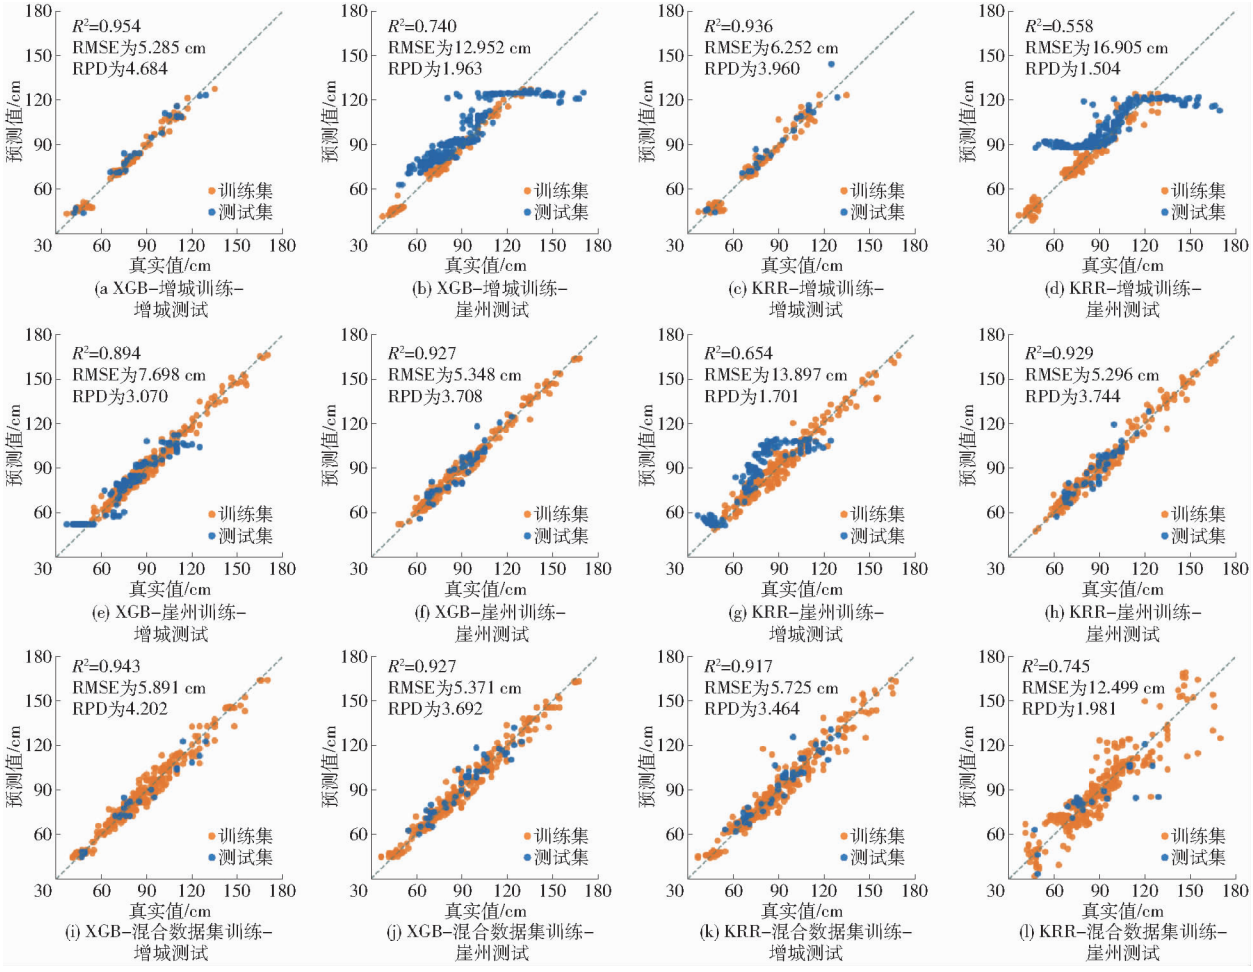

图 5 模型泛化性能对比散点图

Fig. 5 Scatter plots for model generalization performance comparison

显差异：以增城为训练集时，KRR 与 XGB 模型在崖州测试集上精度均显著下降，R_p^2 分别降低 40.1%（从 0.936 降至 0.558）和 21.5%（从 0.943 降至 0.740）；而以崖州为训练集时，两类模型在增城测试集上的精度损失明显更小，KRR 模型 R_p^2 降低 29.5%（从 0.928 降至 0.654），XGB 模型 R_p^2 仅降低 3.6%（从 0.927 降至 0.894）。这表明以崖州试验数据训练的株高回归模型泛化能力更优，核心原因在于崖州数据集涵盖 225 份水稻育种材料，数据分布范围更广，使模型能学习到更全面的株高-特征关联规律，降低对单一地区数据分布的依赖。

增城-崖州混合数据集训练的模型则展现出最均衡的跨地区泛化性能。XGB 模型在增城测试集上 R_p^2 = 0.943、RMSEp 为 5.891 cm、RPD 为 4.202，在崖州测试集上 R_p^2 = 0.927、RMSEp 为 5.371 cm、RPD 为 3.692，两地测试的 R_p^2 差异仅为 0.016；KRR 模型在增城测试集上 R_p^2 = 0.917、RMSEp 为 5.725 cm、RPD 为 3.454，在崖州测试集上 R_p^2 = 0.920、RMSEp 为 5.614 cm、RPD 为 3.532，精度同样保持稳定。这表明整合多区域、多样本数据可有效提高模型的泛化能力。这主要是因为混合数据集覆盖更广泛的株高范围与株型特征，使模型能学习到跨生态区、跨品种的通用株高-特征关联规律，为不同地区、不同品种水稻株高的高精度监测提供了模型支撑。

总之，利用多品种/育种材料数据集可增加样本的多样性，采用高度百分位数、统计参数特征以及冠层剖面面积 3 类特征进行融合可以提高模型捕捉水稻复杂冠层结构特征的能力，而非线性算法则能学习“特征-株高”之间的复杂关系，因此采用“多品种/育种材料数据集-多特征融合-非线性回归”相结合的建模策略，可以提升株高反演模型在跨品种/育种材料应用场景中的泛化能力。

3　讨论

3.1　无人机飞行高度影响

在无人机测量水稻株高过程中，飞行高度对数据采集效率与质量至关重要，需综合权衡飞行时间、地面采样距离及株高估算精度等因素。飞行高度与飞行时间呈反比，低高度需增加航线数量以覆盖相同区域，导致飞行时间延长；而飞行高度大可减少航线，缩短飞行时间。因此，在保证数据质量的前提下，适当提高飞行高度可有效控制飞行时间，提升航测效率。

本研究中，增城数据集采集时无人机飞行高度为 12 m，崖州数据集因地面条件限制采用 20 m 飞行高度。为验证两飞行高度数据的一致性，在增城样地开展对照试验：保持其他参数不变，分别以 12 m 和 20 m 高度采集相同样地的点云数据，提取高度特征后计算得相对误差小于 3%。PUN 等[29]的研究指出，当植被株高小于 60 cm 时，20 m 飞行高度的误差较小，而飞行高度大于 40 m 后误差显著增大。鉴于崖州地区水稻株高多在 60 cm 以上，故认为 12 m 与 20 m 高度采集的数据可共用。

3.2　误差源分析

传统人工测量水稻株高需精准定位茎顶（多数水稻品种的茎顶为叶尖），但叶尖体积小，受 LiDAR 传感器地面采样精度限制，LiDAR 扫描难以准确捕捉叶尖位置。本研究实际统计结果显示，增城-崖州混合数据集中激光点云特征 H_{max} 与株高的相关系数相对较低，这与诸多无人机遥感测量作物株高的研究结论一致[12]。值得注意的是，H_{max} 与株高的相关性在不同数据集间呈现显著差异。如 3.1 节所示，增城数据集中两者相关系数高达 0.97，而崖州数据集中则显著降低至 0.57，导致混合数据集的整体相关性偏低（0.67）。这有力地证明了 H_{max} 这一特征对品种/育种材料的遗传背景与冠层结构异质性具有极高的敏感性。具体而言，增城数据集中品种少且多为直立型，冠层结构均一，确保了 LiDAR 能够稳定可靠地捕捉到冠层顶点，从而实现了 H_{max} 对株高的高精度表征。相反，崖州数据集涵盖了具有多样化遗传背景的育种材料，其冠层叶片表型特征（例如叶片披散程度、叶倾角）差异显著，导致了冠层结构的高度异质性。这种异质性造成了 H_{max} 的采样稳定性急剧下降，导致激光雷达捕获到真实冠层顶点的概率波动极大，进而显著削弱了 H_{max} 与株高的线性关系。综上，H_{max} 对品种/育种材料差异的敏感性可归纳为：当品种/育种材料数量少、株型表型一致时，H_{max} 与实测株高相关性较高；当品种/育种材料多样性高、株型结构差异大时，H_{max} 与株高的相关性则显著降低。由此可见，品种/育种材料的多样性会干扰 LiDAR 点云上界的精准提取，进而带来株高检测误差。

相较于点云上界，下界选择是株高测量中更主要的误差来源[9]。目前减少下界误差的常用方法有 3 类：①播种前采集裸地数据以获取地面高度[7]，但需额外记录裸地信息。②以点云低百分位数作为下界[9]，但在作物种植密集区域无法获取真实地面信息，易导致株高测量值偏小。③利用激光穿透性，通过地面点分类算法提取地面点并实现点云高度归一化[18]，该方法无需提前采集裸地信息，可在作物任一生长阶段测量株高，降低了数据采集成本。本研究采用第 3 类方法。

4 结束语

提出一种基于机载 LiDAR 和多特征融合的非线性回归模型来估算水稻株高,融合高度百分位数、统计参数与冠层剖面面积等特征,取得了较高的检测精度(R^2 = 0.969,RMSE 为 4.73 cm)。与单特征线性回归模型相比,R^2 提升了 7.2%,RMSE 降低了 42.5%,体现多特征互补与非线性算法的优势。研究还表明,样本多样性是提升模型泛化能力的关键因素,增城和崖州地区的数据混合使用能显著提升模型的鲁棒性(R^2 > 0.91,RMSE 小于 6.3 cm),优于单一地区数据集训练的模型。本研究结果为水稻株高的高效、精准检测提供了技术支持,具有较强的应用潜力。

参 考 文 献

[1] LU W, OKAYAMA T, KOMATSUZAKI M. Rice height monitoring between different estimation models using UAV photogrammetry and multispectral technology[J]. Remote Sensing, 2021, 14(1): 78.

[2] HUNT JR E R, HIVELY W D, FUJIKAWA S J, et al. Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring[J]. Remote Sensing, 2010, 2(1): 290 - 305.

[3] 王天一,路梦源,贺刚,等. 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[J]. 农业机械学报,2025,56(11): 76 - 83.
WANG Tianyi, LU Mengyuan, HE Gang, et al. Estimation model of grassland above ground biomass integrating three-dimensional structure and spectral characteristics of vegetation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 76 - 83. (in Chinese)

[4] 范耀冰,吴尚蓉,匡炜,等. 基于无人机高光谱影像的稻谷氮含量估算研究[J]. 农业机械学报,2025,56(1):332 - 343, 423.
FAN Yaobing, WU Shangrong, KUANG Wei, et al. Estimation of nitrogen content in rice grains based on UAV hyperspectral imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 332 - 343, 423. (in Chinese)

[5] WANG Y, KOOTSTRA G, YANG Z, et al. UAV multispectral remote sensing for agriculture: a comparative study of radiometric correction methods under varying illumination conditions[J]. Biosystems Engineering, 2024, 248: 240 - 254.

[6] NIU Y, HAN W, ZHANG H, et al. Estimating maize plant height using a crop surface model constructed from UAV RGB images[J]. Biosystems Engineering, 2024, 241: 56 - 67.

[7] THI PHAN A T, TAKAHASHI K, RIKIMARU A, et al. Method for estimating rice plant height without ground surface detection using laser scanner measurement[J]. Journal of Applied Remote Sensing, 2016, 10(4): 046018.

[8] 王庆,车荧璞,柴宏红,等. 基于无人机可见光与激光雷达的甜菜株高定量评估[J]. 农业机械学报,2021,52(3):178 - 184.
WANG Qing, CHE Yingpu, CHAI Honghong, et al. Quantitative evaluation of sugar beet plant height based on UAV - RGB and UAV - LiDAR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 178 - 184. (in Chinese)

[9] LIU T, ZHU S, YANG T, et al. Maize height estimation using combined unmanned aerial vehicle oblique photography and LiDAR canopy dynamic characteristics[J]. Computers and Electronics in Agriculture, 2024, 218: 108685.

[10] HÜTT C, BOLTEN A, HÜGING H, et al. UAV LiDAR metrics for monitoring crop height, biomass and nitrogen uptake: a case study on a winter wheat field trial[J]. PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 2023, 91(2): 65 - 76.

[11] TILLY N, HOFFMEISTER D, CAO Q, et al. Multitemporal crop surface models: accurate plant height measurement and biomass estimation with terrestrial laser scanning in paddy rice[J]. Journal of Applied Remote Sensing, 2014, 8(1): 083671.

[12] JING L, WEI X, SONG Q, et al. Research on estimating rice canopy height and LAI based on LiDAR data[J]. Sensors, 2023, 23(19): 8334.

[13] 刘建春,陈思,文波龙,等. 基于无人机多光谱遥感的水稻株高估测方法[J]. 遥感信息,2023,38(3):61 - 68.
LIU Jianchun, CHEN Si, WEN Bolong, et al. Rice plant height estimation method based on UAV multispectral-remote sensing[J]. Remote Sensing Information, 2023, 38(3):61 - 68. (in Chinese)

[14] MA B, ZHENG X, LI J, et al. Long-term high-precision monitoring system for laser parameters in large-aperture dual-wavelength LiDAR[J]. Optics & Laser Technology, 2025, 182: 112200.

[15] HAJIHOSSEINLOU M, MAGHSOUDI A, GHEZELBASH R. Intelligent mapping of geochemical anomalies: adaptation of DBSCAN and mean-shift clustering approaches[J]. Journal of Geochemical Exploration, 2024, 258: 107393.

[16] DEWITT J D, WARNER T A, CHIRICO P G, et al. Creating high-resolution bare-earth digital elevation models (DEMs) from stereo imagery in an area of densely vegetated deciduous forest using combinations of procedures designed for lidar point

cloud filtering[J]. GIScience & Remote Sensing, 2017, 54(4): 552 – 572.

[17] ZHENG J, XIANG M, ZHANG T, et al. An improved adaptive grid-based progressive triangulated irregular network densification algorithm for filtering airborne LiDAR data[J]. Remote Sensing, 2024, 16(20): 3846.

[18] VÉGA C, RENAUD J P, DURRIEU S, et al. On the interest of penetration depth, canopy area and volume metrics to improve LiDAR-based models of forest parameters[J]. Remote Sensing of Environment, 2016, 175: 32 – 42.

[19] 李慧姝,黄金辉. 基于 Laspy 的点云数据检查方法[J]. 测绘与空间地理信息,2021,44(6):200 – 202.
LI Huishu, HUANG Jinhui. Point cloud data inspection method based on Laspy[J]. Geomatics and Spatial Information Technology, 2021, 44(6): 200 – 202. (in Chinese)

[20] LUO S, LIU W, REN Q, et al. Leaf area index estimation in maize and soybean using UAV LiDAR data[J]. Precision Agriculture, 2024, 25(4): 1915 – 1932.

[21] LUO S, LIU W, ZHANG Y, et al. Maize and soybean heights estimation from unmanned aerial vehicle (UAV) LiDAR data[J]. Computers and Electronics in Agriculture, 2021, 182: 106005.

[22] 林洁雯,陈建. 基于多源数据与丰度信息融合的森林生物量估算研究[J]. 农业机械学报,2025,56(1):65 – 73.
LIN Jiewen, CHEN Jian. Forest biomass estimation based on multi-source data and abundance information fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 65 – 73. (in Chinese)

[23] 侯轶,张霞,郑海光,等. 综合光谱多特征与 XGBoost 模型的土壤高光谱遥感分类方法[J]. 农业机械学报,2025,56(11):612 – 620.
HOU Yi, ZHANG Xia, ZHENG Haiguang, et al. Hyperspectral remote sensing classification method for soil by combining spectral multi-feature and XGBoost model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 612 – 620. (in Chinese)

[24] WANG Z, MU L, MIAO H, et al. An innovative application of machine learning in prediction of the syngas properties of biomass chemical looping gasification based on extra trees regression algorithm[J]. Energy, 2023, 275: 127438.

[25] WU X H, PAN C, ZHANG K Y, et al. Nuclear mass predictions of the relativistic continuum Hartree-Bogoliubov theory with the kernel ridge regression[J]. Physical Review C, 2024, 109(2): 024310.

[26] RIMAL Y, SHARMA N, ALSADOON A. The accuracy of machine learning models relies on hyperparameter tuning: student result classification using random forest, randomized search, grid search, bayesian, genetic, and optuna algorithms[J]. Multimedia Tools and Applications, 2024, 83(30): 74349 – 74364.

[27] 鲁向晖,龚荣新,张海娜,等. 基于无人机多光谱遥感的矮林芳樟光合参数估测[J]. 农业机械学报,2023,54(10):179 – 187.
LU Xianghui, GONG Rongxin, ZHANG Haina, et al. Estimation of photosynthetic parameters of cinnamomum camphora in dwarf forest based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 179 – 187. (in Chinese)

[28] LIU P, WANG S, ZHAO P. Robust estimation and test for Pearson's correlation coefficient[J]. Random Matrices: Theory and Applications, 2024, 13(4): 2450023.

[29] PUN MAGAR L, SANDIFER J, KHATRI D, et al. Plant height measurement using UAV-based aerial RGB and LiDAR images in soybean[J]. Frontiers in Plant Science, 2025, 16: 1488760.