doi:10.6041/j.issn.1000-1298.2019.10.018

基于地基 LiDAR 高度指标的小麦生物量监测研究

邱小雷　方　圆　郭　泰　程　涛　朱　艳　姚　霞
(南京农业大学国家信息农业工程技术中心, 南京 210095)

摘要: 为探讨 LiDAR 监测作物生物量的可行性和方法,以小麦为研究对象,通过田间试验获取关键生育期的小麦 LiDAR 点云高度指标和地上部生物量,基于幂函数回归与支持向量回归、利用十折交叉验证法分别进行特征选择和模型构建,选取各算法最优的全生育期小麦地上部生物量监测模型,并在测试集上对模型的预测能力进行检验与比较。结果表明:利用 H_{95} 和生育期特征所构建的全生育期支持向量回归模型精度最高,训练集上决定系数 R^2 达到 0.814,测试集结果(R^2 = 0.821,RMSE 为 1.730 t/hm^2,RRMSE 为 32.77%)表明,模型具有较好的准确性;利用 H_{mean} 所构建的全生育期幂函数回归模型决定系数 R^2 达到 0.809,测试集结果(R^2 = 0.815,RMSE 为 1.760 t/hm^2,RRMSE 为 33.33%)也表明模型具有较好的准确性;高度指标估测小麦生物量具有先天局限性,所构建模型较适宜于监测小麦地上部生物量小于 10 t/hm^2 的情况,在超过 10 t/hm^2 的样本集上,95% 的模型预测值被低估,RMSE 呈指数增长;生育期特征有利于提升监测模型预测精度。

关键词: 小麦; 生物量; 地基 LiDAR; 高度指标
中图分类号: S512.1; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2019)10-0159-08

Monitoring of Wheat Biomass Based on Terrestrial-LiDAR Height Metric

QIU Xiaolei　FANG Yuan　GUO Tai　CHENG Tao　ZHU Yan　YAO Xia
(*National Engineering and Technology Center for Information Agriculture*, *Nanjing Agricultural University*, *Nanjing* 210095, *China*)

Abstract: Rapid, nondestructive and accurate monitoring of crop biomass is of great significance for crop productivity estimation and intelligent management. In order to explore the feasibility of monitoring crop biomass with light detection and ranging (LiDAR), LiDAR point cloud height metrics and aboveground biomass were obtained from field trials at key growth stages of wheat. Then based on the power function regression and support vector regression, the ten-fold cross-validation method was used to pick features and construct models, and the optimal wheat aboveground biomass monitoring models for whole growth period were selected respectively. Finally, the prediction abilities of the two models were tested and compared on the test set. The results showed that the support vector regression model constructed by the H_{95} and growth period provided the highest accuracy with an R^2 being as high as 0.814 on training set, and its test results were with R^2 of 0.821, RMSE of 1.730 t/hm^2, and RRMSE of 32.77%, which indicated that the model possessed good accuracy and adaptability. The power function regression model constructed by H_{mean} provided an R^2 of 0.809, and its test results were with R^2 of 0.815, RMSE of 1.760 t/hm^2, and RRMSE of 33.33%, which also indicated that the model possessed good accuracy and adaptability. Estimation of wheat biomass by a height metric had inherent limitations, and the two models were more suitable for monitoring the aboveground biomass of wheat values less than 10 t/hm^2. On the whole sample set with aboveground biomass exceeding 10 t/hm^2, 95% of the predicted values of the models were underestimated and RMSE was increased exponentially. The feature of growth period was helpful to improve the prediction accuracy of the monitoring model.

Key words: wheat; biomass; terrestrial-LiDAR; height metric

收稿日期: 2019-03-21　修回日期: 2019-05-05
基金项目: 国家重点研发计划项目(2016YFD0300601)、中央高校基本科研业务费专项资金项目(SYSB201801)和国家自然科学基金项目(31871524)
作者简介: 邱小雷(1982—),男,助理研究员,博士生,主要从事农业信息技术研究,E-mail: qiuxiaolei@njau.edu.cn
通信作者: 姚霞(1977—),女,教授,博士生导师,主要从事农情遥感监测研究,E-mail: yaoxia@njau.edu.cn

0 引言

农作物生物量是反映其生长状况的重要指标，是形成作物产量的基础，其大小与作物群体光合利用、环境因子胁迫、产量和品质形成等因素密切相关[1-2]，监测作物生物量对作物生产能力估计及田间管理具有重要的意义。传统监测小麦生物量的方法是人工田间采样后测量，不仅具有一定的破坏性，而且工作量大、成本高、耗时长，不能及时反映小麦的生长状况[3]。遥感技术具有快速、动态、无损等优点，应用遥感技术监测小麦生物量的研究也越来越多[3-5]。常规遥感技术多采用被动遥感的方式，通过获取植被光谱信息反演小麦生物量，监测手段包括各种地面光谱仪、无人机影像以及卫星遥感影像等，但是光学遥感对天气条件非常敏感，不利于随时观测[1]。LiDAR 是近年来迅速发展起来的一门新技术，与光学遥感技术不同的是，LiDAR 是一种主动传感器，不受周围环境光条件限制，具有较强的穿透能力，在植被结构参数获取方面具有显著的优势[6]。

LiDAR 在监测森林生物量的研究中已经取得了较好的结果[7-9]，估测精度相对较高，但在农作物上的应用还处于起步阶段。WANG 等[10]将机载 LiDAR 数据的派生指标、高光谱影像的植被指数两者相结合，提高了对玉米生物量的估测精度。TILLY 等[11]以水稻为对象，基于地基 LiDAR 构建作物表面模型（CSM），提取植物株高，然后与田间实测作物生物量进行相关分析，建立了基于 CSM 的生物量回归模型，实现了水稻生物量评估。将 LiDAR 技术应用于作物生物量监测可以提高估测精度，本文在现有研究基础上，以小麦为对象，地基 LiDAR 为监测平台，借鉴相关研究方法，扩展试验设计，构建和比较不同的高度指标监测模型，探索估测小麦生物量的方法。

1 材料与方法

1.1 试验设计

试验于 2016 年 10 月—2017 年 6 月在国家信息农业工程技术中心如皋试验示范基地（32°15′N，120°38′E）进行。试验选用 2 个品种：扬麦 15（V1）、扬麦 16（V2）；3 个氮肥水平：0 kg/hm^2（N0）、150 kg/hm^2（N1）、300 kg/hm^2（N2）；2 个密度水平：行距 25 cm（D1，2.4 × 10^{6}株/hm^2）、行距 40 cm（D2，1.5 × 10^{6}株/hm^2）。采用随机区组设计，重复 3 次，共计 36 个小区，单个小区面积为 30 m^2（6 m × 5 m）。

1.2 数据获取与处理

1.2.1 生物量的测定

在小麦的分蘖期、拔节期、抽穗期、开花期、灌浆期各进行 1 次田间取样，每小区取 2 行 × 0.3 m，按植株器官分离，绿色叶片按叶位分离。室内测定时，样品在 105°杀青并在 80°干燥后称量，得到植株不同部位器官质量以及绿色叶片的总干质量，进而计算得到关键生育期各小区单位土地面积干物质量。

1.2.2 高度指标的获取

在小麦关键生育期田间取样的同时，利用 RIEGL - VZ 1000 型地面激光雷达（图 1）获取小麦植株的点云数据。地基 LiDAR 采用 8 站点方案，扫描模式为 60 模式，即角分辨率为 0.06°，每转过 0.06°获取一次点数据，站点方案见图 2。

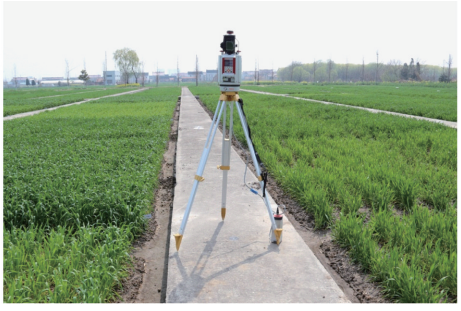

图 1 地基 LiDAR 田间测试图（仪器架设高度为 1.5 m）

Fig. 1 RIEGL - VZ 1000 LiDAR working diagram in field (height of instrument was 1.5 m)

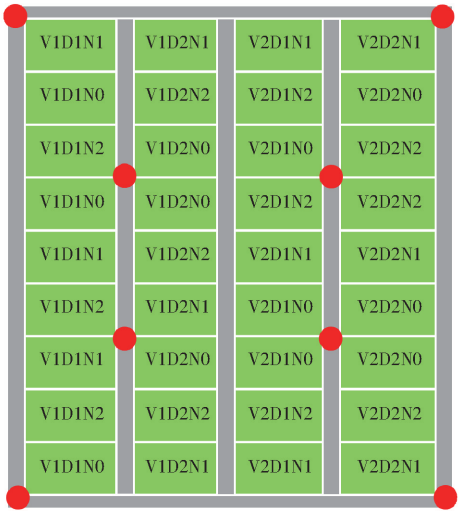

图 2 站点方案示意图

Fig. 2 Scanner position scheme

使用 RiSCAN PRO 软件进行小麦植株点云数据预处理，得到地面数字高程模型（Digital elevation model，DEM）和关键生育期的数字表面模型（Digital surface model，DSM），通过差值生成每个生育期的冠层高度模型（Canopy height model，CHM），最后基于 IDL 语言开发脚本提取高度特征参数[12]。目前在

监测植物生物量的研究中，主要使用的高度特征指标有平均值 H_{mean}、最大值 H_{max}、最小值 H_{min}、百分位值 H_p 等[11,13]，借鉴前人经验，本文选 H_{max}、H_{95}、H_{90}、H_{85}、H_{80}、H_{mean}、H_{min} 等特征指标作为研究对象。

1.3　研究方法

1.3.1　非线性回归

非线性回归是表示输入变量到输出变量之间的曲线函数关系。对于样本数据集 $T=\{(x_1,y_1),(x_2,y_2),\cdots,(x_n,y_n)\}$，寻找一条函数曲线 $f(x)$，不但能很好地拟合已有样本集数据且对新的数据也能很好地预测[14]。本文采用幂函数方程拟合曲线，该过程即求解回归方程中参数 a、b，从而建立模型量化高度指标与小麦生物量的关系，幂函数方程为

$$f(x)=ax^b \tag{1}$$

1.3.2　支持向量回归

支持向量回归（Support vector regression，SVR）是支持向量机（Support vector machine，SVM）在回归应用方面的推广，是一种基于结构风险最小化原则的机器学习算法[15]，具有良好的泛化能力，可较好解决小样本下的学习问题，同时因使用核函数将复杂的空间映射计算简单化，能有效处理非线性回归预测问题，已成功地应用于多种植物生物量的预测[16-17]。SVR 通过特征空间估计内积的核，隐式地实现输入变量到高维特征空间的映射，然后在高维特征空间中构建线性回归函数，对应原空间非线性问题的求解，其数学模型如下

$$y=\sum_{i=1}^{n}(a_i-a_i')k(x_i+x')+b \tag{2}$$

式中 $k(x_i+x')$ 为核函数，a_i、a_i' 有小部分不为 0，所对应的样本点称为支持向量。a_i-a_i' 和 b 通常在拟合中自动优化得到[18]。不同的核函数类型及参数对模型的泛化能力影响较大，常用的核函数有线性核函数、多项式核函数、径向基核函数、Sigmoid 核函数，其中高斯径向基核函数（RBF 核函数）具有很好的泛化能力，并且能支持非线性回归，本研究中选取的核函数为 RBF 核函数，公式为

$$k(x_i+x')=\exp\left(-\frac{\|x_i-x'\|^2}{2\sigma^2}\right) \tag{3}$$

式中　x_i——样本点

x'——核函数中心点

σ——宽度参数，控制了函数的径向作用范围

通过 RBF 核函数能够将原始空间映射到无穷维空间。本文使用支持向量回归建立小麦生物量监测模型时增加样本中生育期作为新特征维度，将生育期经过 one - hot 编码预处理后再用于建模和检验。

1.3.3　特征选择与模型构建

将 5 个关键生育期共获取的 180 组数据每生育期随机抽取 3 ~6 组数据，共计 20 组作为测试集，用于独立检验和评价。剩余 160 组数据作为建模集，基于十折交叉验证法分别采用幂函数回归与支持向量回归对建模样本进行特征选择、模型训练，构建各算法最优的全生育期小麦生物量监测模型。具体步骤是将建模数据集随机分成 10 个子集，轮流将其中 9 个作为训练集，1 个作为验证集，首先对 H_{max}、H_{95}、H_{90}、H_{85}、H_{80}、H_{mean}、H_{min} 等特征参数分别迭代 10 次，用 10 次结果的平均值作为评分项，选择特征参数；然后将所选特征参数在 10 次交叉验证结果中的最优值作为模型参数估计，构建监测模型；最后在独立测试集上进行检验和评价，评估模型的泛化能力。

1.3.4　模型评价指标

模型评价指标包括决定系数 R^2、均方根误差（RMSE）和相对均方根误差（RRMSE），计算公式为

$$R^2=1-\frac{\sum_{i=1}^{n}(O_i-P_i)^2}{\sum_{i=1}^{n}(O_i-\overline{P})^2} \tag{4}$$

$$R_{MSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i-P_i)^2} \tag{5}$$

$$R_{RMSE}=\frac{\sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i-P_i)^2}}{\overline{O}}\times 100\% \tag{6}$$

式中　n——样本数量

O_i——样本 i 的实测值

P_i——对应样本 i 的模型预测值

$\overline{O}$——实测值 O_i 的平均值

$\overline{P}$——模型预测值 P_i 的平均值

R_{MSE}——均方根误差

R_{RMSE}——相对均方根误差

1.3.5　建模工具

基于 Python 3.5 环境，利用 Pandas、Scipy 和 Sklearn 等扩展模块开发所需数据处理、分析建模和检验评价的程序。Scipy 模块 optimize 组件中 curve_fit 函数可实现曲线拟合，用于构建幂函数回归模型。应用 Sklearn 模块中 model_selection 组件的 train_test_split 切分数据样本集，Sklearn 还提供了包括支持向量回归等在内全面的机器学习算法与丰富的调用接口[19]。SVR 算法由 Sklearn 模块中的 SVM 组件实现，影响 SVR 性能的主要超参数有核函数 kernel、惩罚系数 C 和核系数 g，C 过大或过小泛化能力变差，g 过大易发生欠拟合，反之则可能过拟

合,根据经验本文设置惩罚系数 C 为 1 000,核系数 g 为 0.001。

2 结果与分析

2.1 关键生育期数据结果

地基 LiDAR 点云数据经过点云配准、拼接等预处理后,生成小麦关键生育期的点云图(图 3),然后结合地面高程模型,应用 IDL 脚本提取高度特征参数。小麦地上部生物量经田间取样,室内测定后获得。如图 4 所示,关键生育期数据结果表明,小麦的高度指标 H_{mean} 由分蘖到灌浆随生育进程变化速率由大趋小,地上部生物量变化速率则由小趋大。

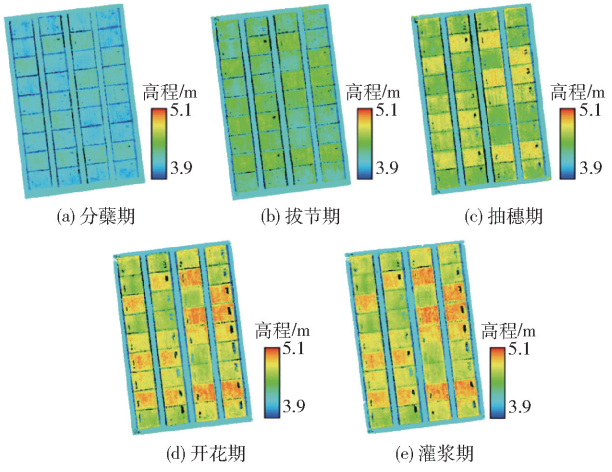

图 3 不同生育时期小麦点云图

Fig. 3 Wheat point clouds diagram in different growth stages

2.2 高度特征指标选择

利用小麦全生育期试验数据,采用十折交叉检验法,基于幂函数回归与支持向量回归,分别选择高度特征指标用于构建模型。基于幂函数回归模型的验证集上各高度指标 10 次结果的均值如表 1 所示,H_{mean} 得分最高,R^2 = 0.805,RMSE 为 1.439 t/hm^2,RRMSE 为 30.43%,因此构建幂函数回归模型时选择 H_{mean} 指标。

基于支持向量回归模型验证集上各高度指标 10 次结果的均值如表 2 所示,只使用高度特征指标时 H_{mean} 得分最高,R^2 = 0.797,RMSE 为 1.462 t/hm^2,RRMSE 为30.82%;增加生育期特征后 H_{95} 得分最高,R^2 = 0.807,RMSE 为 1.437 t/hm^2,RRMSE 为 30.31%,且优于单高度指标 H_{mean},因此构建支持向量回归模型时选择 H_{95} 与生育期两个特征指标。

2.3 小麦生物量监测模型

选择 H_{mean} 指标 10 次交叉验证结果中的最优值作为模型参数估计,构建全生育期幂函数回归模型,

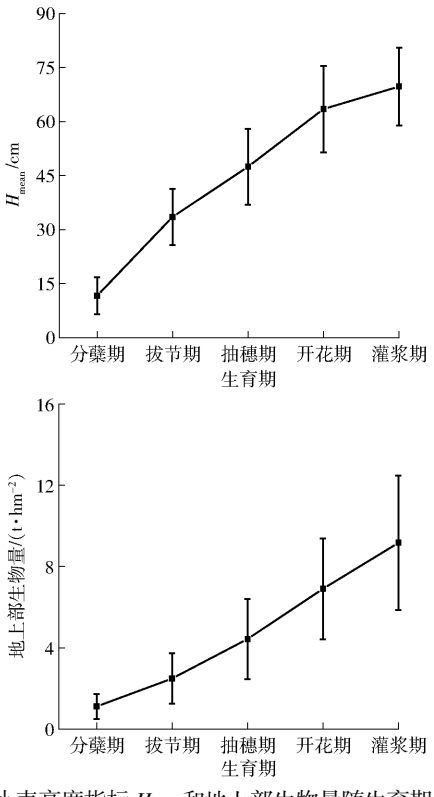

图 4 小麦高度指标 H_{mean} 和地上部生物量随生育期的变化

Fig. 4 Variations of height index H_{mean} and aboveground biomass with growth period of wheat

表 1 幂函数回归模型高度特征指标结果

Tab. 1 Results of height characteristic indexes of power function regression model

高度指标	模型评价指标		
	R^2	RMSE/(t·hm^{-2})	RRMSE/%
H_{max}	0.789	1.505	32.15
H_{95}	0.800	1.456	30.85
H_{90}	0.803	1.460	30.63
H_{85}	0.804	1.441	30.53
H_{80}	0.804	1.439	30.50
H_{mean}	0.805	1.439	30.43
H_{min}	0.749	1.595	33.70

表 2 支持向量回归模型特征指标结果

Tab. 2 Results of feature indexes of support vector regression model

高度指标	模型评价指标			增加生育期特征后模型评价指标		
	R^2	RMSE/(t·hm^{-2})	RRMSE/%	R^2	RMSE/(t·hm^{-2})	RRMSE/%
H_{max}	0.767	1.580	33.75	0.785	1.521	32.41
H_{95}	0.793	1.484	31.39	0.807	1.437	30.31
H_{90}	0.794	1.479	31.26	0.805	1.442	30.42
H_{85}	0.794	1.477	31.19	0.804	1.449	30.59
H_{80}	0.792	1.483	31.33	0.803	1.452	30.65
H_{mean}	0.797	1.462	30.82	0.803	1.444	30.37
H_{min}	0.755	1.551	32.81	0.793	1.444	30.59

结果如图 5 所示，幂函数回归模型的决定系数 R^2 为 0.809，验证集 R^2 为 0.907，RMSE 和 RRMSE 分别为 0.887 t/hm^2 和 23.17%。

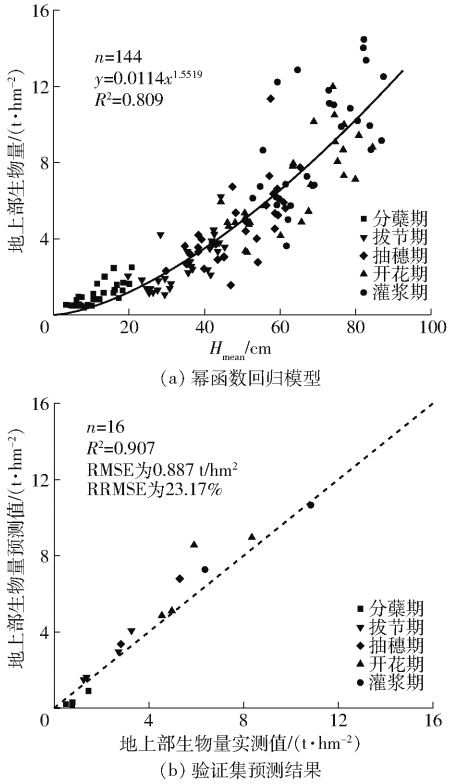

图 5　幂函数回归模型构建及验证集的预测结果

Fig. 5　Establishment of power function regression model and prediction results on verification set

选择 H_{95} 与生育期两个特征指标在 10 次交叉验证结果中的最优值作为模型参数估计，构建全生育期支持向量回归模型，模型在建模集上的检验结果如图 6 所示，其中训练集 R^2 为 0.814，RMSE 和 RRMSE 分别为 1.492 t/hm^2 和 30.95%，验证集 R^2 为 0.919，RMSE 和 RRMSE 分别为 0.826 t/hm^2 和 21.59%。

2.4　模型评价与比较

已构建的全生育期小麦生物量监测模型在独立测试集上的检验结果如图 7 所示，幂函数回归模型 R^2 为 0.815，RMSE 和 RRMSE 分别为 1.760 t/hm^2 和 33.33%，支持向量回归模型 R^2 为 0.821，RMSE 和 RRMSE 分别为 1.730 t/hm^2 和 32.77%。结果表明，应用地基 LiDAR 高度指标监测小麦生物量时，增加生育期特征的支持向量回归模型略优于只使用高度指标的幂函数回归模型。但随着小麦生物量的增长，两模型的预测精度明显下降，均出现饱和，一方面这是由于从开花期到灌浆期小麦穗持续增长，进而生物量也随之增长，但是小麦的株高变化不大，从而造成生育后期的低估现象，另一方面可能是因为高密度高氮肥田块与正常田块相比生育后期株高基本一致，但群体较大，高度指标监测模型尚无法准确预测这部分田块小麦地上部生物量。

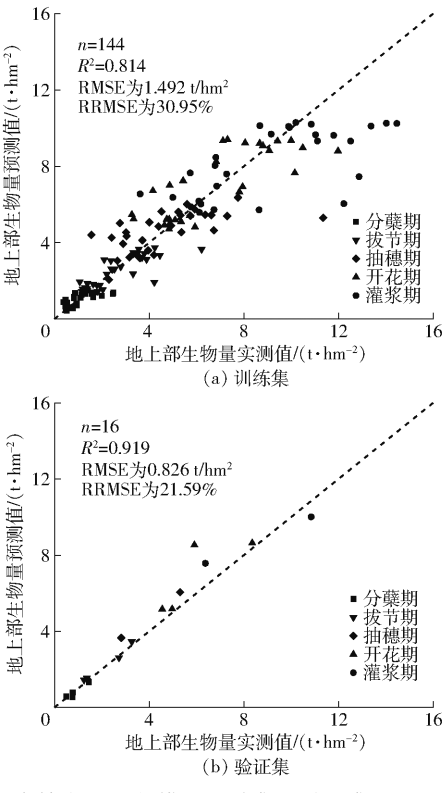

图 6　支持向量回归模型训练集和验证集的预测结果

Fig. 6　Prediction results of support vector regression model on training set and verification set

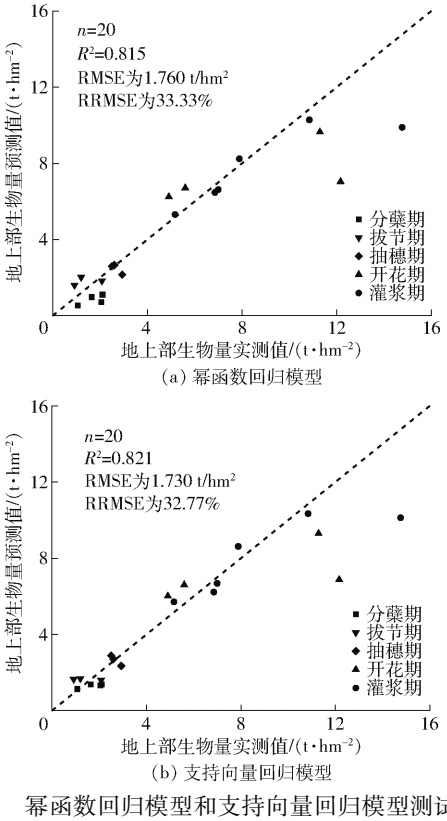

图 7　幂函数回归模型和支持向量回归模型测试集的预测结果

Fig. 7　Prediction results of power function regression model and support vector regression model on test set

3 讨论

3.1 不同高度指标监测小麦生物量的结果

LiDAR 通过发射激光和接收返回信号的方式,可以获取高精度的植被空间结构信息与冠层底部地形信息[20-21],因此可以快速地估算出小麦的高度特征,进而反演出生物量。现有的研究大部分都利用不同的高度指标来反演生物量,包括 H_{max}、H_{95}、H_{90}、H_{85}、H_{80}、H_{mean}、H_{std}、H_{cv} 等[22-24]。本文选取高度指标 H_{max}、H_{95}、H_{90}、H_{85}、H_{80}、H_{mean}、H_{min},通过十折交叉验证法分别利用幂函数回归与支持向量回归选择特征指标,比较了不同高度指标估测小麦生物量的精度。结果表明,采用幂函数回归模型时,H_{mean} 的估测效果最好,采用支持向量回归模型时,选择 H_{95} 与生育期两个特征指标建模效果最好。株高是小麦生长变化的关键特征,虽然幂函数回归模型与单高度特征支持向量回归模型中 H_{mean} 的效果最好,但 H_{95}、H_{90}、H_{85} 和 H_{80} 均反映株高特征,且在数值上与 H_{mean} 差异不大,或为比例关系,因此所建立的生物量监测模型估测精度相差很小。

3.2 高度指标监测模型的预测能力

小麦地上部生物量由绿叶、茎鞘、穗 3 部分组成,不同器官间的干物质积累与转运随品种、环境条件而异[25]。株高随着叶、茎、穗的生长动态变化,与地上部生物量有着显著正相关关系,图 4 结果表明开花前小麦随着株高变化地上部生物量呈几何级增长,但是到了生育后期株高生长逐渐趋于停止,而地上部生物量还在不断积累,造成高度指标估测小麦生物量的先天局限性。如图 8 所示为全样本集上小麦地上部生物量实测值与两个全生育期监测模型预测值的分布,实测值的下四分位数、中位数、上四分位数与监测模型基本一致,最小值与支持向量回归模型一致,与幂函数回归模型稍有差异,但实测最大值与两个监测模型差异明显,当地上部生物量较大时监测模型的预测能力明显不足。地上部生物量小于 10 t/hm^2 的全生育期样本集的幂函数回归模型 RMSE 为 1.098 t/hm^2,支持向量回归模型 RMSE 为 0.970 t/hm^2,大于 10 t/hm^2 的全生育期样本集两个监测模型 RMSE 分别为 3.611 t/hm^2 与 3.826 t/hm^2,95% 预测值都被低估。如图 9 所示,样本按实测值分组后地上部生物量小于 10 t/hm^2 的模型 RMSE 在 1.0 t/hm^2 左右波动,但是超过 10 t/hm^2 时,预测模型 RMSE 呈指数增长。

3.3 生育期特征分析

在单高度指标特征选择的结果中,全生育期幂函数回归模型精度均高于支持向量回归模型,但增加生育期特征后,支持向量回归模型精度得到提升,H_{95} 与生育期两个特征指标的得分最高,所构建的监测模型精度也最高。进一步利用建模集中 160 组样本,基于单个生育期构建 H_{mean} 幂函数回归小麦生物量监测模型,并在独立测试集的 20 组样本上检验。如图 10 所示,单生育期幂函数回归模型测试集预测结果略优于全生育期构建的幂函数回归模型,但不如支持向量回归模型,生育期特征有利于监测模型预测精度提升。由于小麦不同生育期的形态结构和生理特性具有明显差异,影响了单生育期幂函数回归模型的变化趋势,没有形成一致规律。

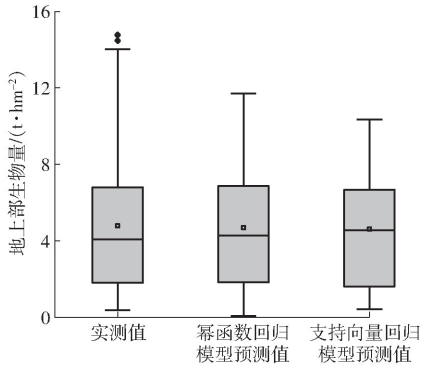

图 8 小麦地上部生物量实测值与模型预测值的分布

Fig. 8 Distribution of measured and predicted aboveground biomass of wheat

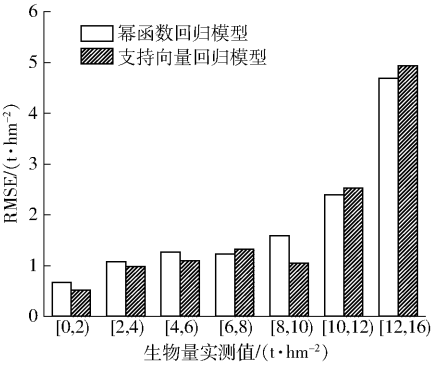

图 9 样本按实测生物量分组后 RMSE 变化图

Fig. 9 Trend of RMSE after grouping samples according to measured biomass

3.4 支持向量回归模型的超参数选择

机器学习算法的性能依赖于超参数的选择,支持向量回归模型常用的超参数调试方法有经验凑试法、网格法,以及基于梯度下降算法、遗传算法、粒子群算法的调优方法等[26-28]。由于本文所选的建模特征较少,根据经验设置惩罚系数 C 为1 000,核系数 g 为 0.001,为了探讨经验值是否合理,以 R^2 为评价指标,迭代计算 C 的范围为 1 ~ 5 000,g 的范围为 0.000 1 ~ 0.01,如图 11 所示,所选经验值分布在高分范围内。

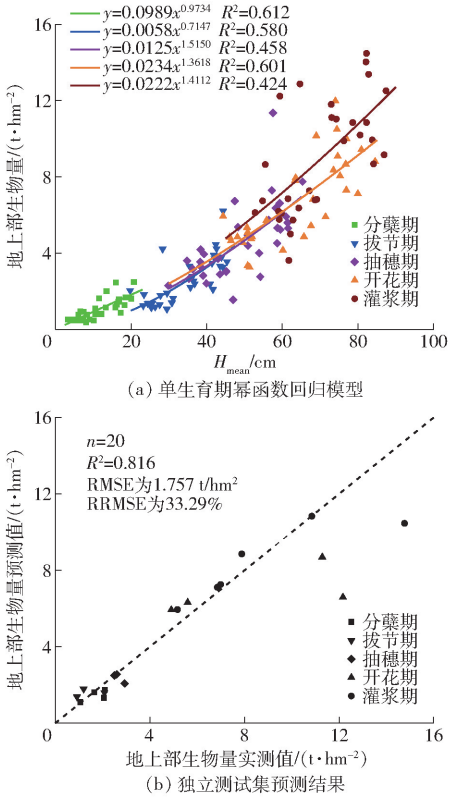

(a) 单生育期幂函数回归模型

(b) 独立测试集预测结果

图 10　单生育期幂函数回归模型构建及测试集的预测结果

Fig. 10　Establishment of power function regression model for single growth period and prediction results on test set

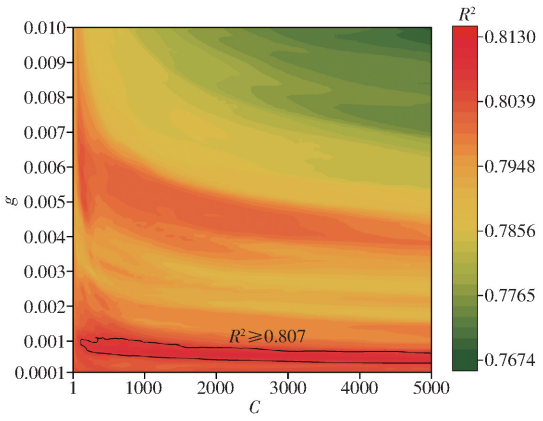

图 11　支持向量回归模型超参数评价

Fig. 11　Superparametric evaluation of support vector regression model

4　结论

(1)利用高度指标 H_{mean} 与实测生物量构建全生育期幂函数回归模型，幂函数回归模型决定系数 R^2 为 0.809，验证集 R^2 为 0.907，RMSE 和 RRMSE 分别为 0.887 t/hm² 和 23.17%，独立测试集幂函数回归模型 R^2 为 0.815，RMSE 和 RRMSE 分别为 1.760 t/hm² 和 33.33%。

(2)利用 H_{95} 和生育期两个特征指标与实测生物量构建全生育期支持向量回归模型，训练集模型 R^2 为 0.814，RMSE 和 RRMSE 分别为 1.492 t/hm² 和 30.95%，验证集 R^2 为 0.919，RMSE 和 RRMSE 分别为 0.826 t/hm² 和 21.59%，独立测试集上 R^2 为 0.821，RMSE 和 RRMSE 分别为 1.730 t/hm² 和 32.77%。

(3)由于高度指标估测小麦生物量的先天局限性，两模型较适宜于小麦地上部生物量小于 10 t/hm² 的情况，当超过 10 t/hm² 时，样本集上 95% 模型预测值被低估，RMSE 呈指数增长。

(4)基于单生育期构建的幂函数回归模型独立测试集检验结果 R^2 为 0.816，RMSE 和 RRMSE 分别为 1.757 t/hm² 和 33.29%，所构建的支持向量回归模型均优于全生育期幂函数回归模型，生育期特征有利于提升监测模型预测精度。

参　考　文　献

[1] 杜鑫，蒙继华，吴炳方. 作物生物量遥感估算研究进展[J]. 光谱学与光谱分析，2010，30(11)：3098－3102.
DU Xin, MENG Jihua, WU Bingfang. Overview on monitoring biomass with remote sensing[J]. Spectroscopy and Spectral Analysis, 2010, 30(11): 3098－3102. (in Chinese)

[2] 郑玲，朱大洲，王成，等. 基于 LabVIEW 的小麦生物量检测系统[J/OL]. 农业机械学报，2013，44(9)：214－218.
ZHENG Ling, ZHU Dazhou, WANG Cheng, et al. Detection system for wheat biomass based on LabVIEW [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(9): 214－218. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20130938&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2013.09.038. (in Chinese)

[3] 庄东英，李卫国，武立权. 冬小麦生物量卫星遥感估测研究[J]. 干旱区资源与环境，2013，27(10)：158－162.
ZHUANG Dongying, LI Weiguo, WU Liquan. Estimating winter wheat biomass based on satellite remote sensing[J]. Journal of Arid Land Resources and Environment, 2013, 27(10): 158－162. (in Chinese)

[4] FU Y, YANG G, WANG J, et al. Winter wheat biomass estimation based on spectral indices, band depth analysis and partial least squares regression using hyperspectral measurements[J]. Computers and Electronics in Agriculture, 2014, 100: 51－59.

[5] YUE J, YANG G, LI C, et al. Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models[J]. Remote Sensing, 2017, 9(7): 708.

[6] 胡凯龙，刘清旺，李世明，等. 运用融合纹理和机载 LiDAR 特征模型估测森林地上生物量[J]. 东北林业大学学报，2018，46(1)：52－57.
HU Kailong, LIU Qingwang, LI Shiming, et al. Estimation of forest aboveground biomass by fusion of optical image texture and

airborne LiDAR metrics[J]. Journal of Northeast Forestry University, 2018, 46(1): 52 - 57. (in Chinese)
[7] 李德仁,王长委,胡月明,等. 遥感技术估算森林生物量的研究进展[J]. 武汉大学学报(信息科学版),2012,37(6):631 - 635.
LI Deren, WANG Changwei, HU Yueming, et al. General review on remote sensing-based biomass estimation[J]. Geomatics and Information Science of Wuhan University, 2012, 37(6): 631 - 635. (in Chinese)
[8] STOVALL A E L, VORSTER A G, ANDERSON R S, et al. Non-destructive aboveground biomass estimation of coniferous trees using terrestrial LiDAR[J]. Remote Sensing of Environment, 2017, 200: 31 - 42.
[9] OLSCHOFSKY K, MUES V, KÖHL M. Operational assessment of aboveground tree volume and biomass by terrestrial laser scanning[J]. Computers and Electronics in Agriculture, 2016, 127: 699 - 707.
[10] WANG C, NIE S, XI X, et al. Estimating the biomass of maize with hyperspectral and LiDAR data[J]. Remote Sensing, 2017, 9(1): 11.
[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: 083671.
[12] 翟苗苗. 基于地面激光雷达的小麦生物量和茎蘖数估算研究[D]. 南京:南京农业大学,2018.
ZHAI Miaomiao. Estimating wheat biomass and tiller number based on terrestrial laser scanning[D]. Nanjing: Nanjing Agricultural University, 2018. (in Chinese)
[13] LUO S, CHEN J, WANG C, et al. Effects of LiDAR point density, sampling size and height threshold on estimation accuracy of crop biophysical parameters[J]. Optics Express, 2016, 24(11):11578 - 11593.
[14] 盖钧镒. 试验统计方法[M]. 4 版. 北京:中国农业出版社,2013:189 - 202.
[15] 唐发明. 基于统计学习理论的支持向量机算法研究[D]. 武汉:华中科技大学,2005.
TANG Faming. Study of support vector machines algorithm based on statistical learning theory[D]. Wuhan: Huazhong University of Science and Technology, 2005. (in Chinese)
[16] 尚珂. 基于支持向量机回归的草地地上生物量遥感估测研究[D]. 昆明:西南林业大学,2015.
SHANG Ke. The study of grassland above ground biomass inversion based on support vector machine regression[D]. Kunming: Southwest Forestry University, 2015. (in Chinese)
[17] 邱赛,邢艳秋,徐卫华,等. 星载大光斑 LiDAR 与 HJ - 1A 高光谱数据联合估测区域森林地上生物量[J]. 生态学报,2016,36(22):7401 - 7411.
QIU Sai, XING Yanqiu, XU Weihua, et al. Estimation of regional forest aboveground biomass combining spaceborne large footprint LiDAR and HJ - 1A hyperspectral images[J]. Acta Ecologica Sinica, 2016, 36(22): 7401 - 7411. (in Chinese)
[18] 王大鹏. 支持向量回归与常用近似模型的非线性预测性能比较研究[J]. 工业控制计算机,2010,23(9):56 - 58,52.
WANG Dapeng. Comparative study of nonlinear prediction capacity of support vector regression and typical surrogate models [J]. Industrial Control Computer, 2010, 23(9): 56 - 58, 52. (in Chinese)
[19] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: machine learning in Python[J]. Journal of Machine Learning Research, 2011, 12: 2825 - 2830.
[20] EITEL J U H, MAGNEY T S, VIERLING L A, et al. LiDAR based biomass and crop nitrogen estimates for rapid, non-destructive assessment of wheat nitrogen status[J]. Field Crops Research, 2014, 159:21 - 32.
[21] 李增元,刘清旺,庞勇. 激光雷达森林参数反演研究进展[J]. 遥感学报,2016,20(5):1138 - 1150.
LI Zengyuan, LIU Qingwang, PANG Yong. Review on forest parameters inversion using LiDAR[J]. Journal of Remote Sensing, 2016, 20(5):1138 - 1150. (in Chinese)
[22] 刘清旺,李增元,陈尔学,等. 利用机载激光雷达数据提取单株木树高和树冠[J]. 北京林业大学学报,2008,30(6):83 - 89.
LIU Qingwang, LI Zengyuan, CHEN Erxue, et al. Extracting height and crown of individual tree using airborne LiDAR data [J]. Journal of Beijing Forestry University, 2008, 30(6):83 - 89. (in Chinese)
[23] HÄMMERLE M, HÖFLE B. Effects of reduced terrestrial LiDAR point density on high-resolution grain crop surface models in precision agriculture[J]. Sensors, 2014, 14(12): 24212 - 24230.
[24] 杨凡. 基于无人机激光雷达和高光谱的冬小麦生物量反演研究[D]. 西安:西安科技大学,2017.
YANG Fan. Estimation of winter wheat aboveground biomass with UAV LiDAR and hyperspectral data[D]. Xi'an: Xi'an University of Science and Technology, 2017. (in Chinese)
[25] 刘铁梅. 小麦光合生产与物质分配的模拟模型[D]. 南京:南京农业大学,2000.
LIU Tiemei. Simulation on photosynthetic production and dry matter partitioning in wheat[D]. Nanjing: Nanjing Agricultural University, 2000. (in Chinese)
[26] 郭一楠,程健,杨梅. 支持向量回归超参数的混沌文化优化选择方法[J]. 控制与决策,2010,25(4):525 - 530.
GUO Yinan, CHENG Jian, YANG Mei. Selection method for hyper-parameters of support vector regression by chaotic cultural algorithm[J]. Control and Decision, 2010, 25(4): 525 - 530. (in Chinese)
[27] CHAPPELLE O, VAPNIK V, BOUSQUET O, et al. Choosing multiple parameters for support vector machines[J]. Machine Learning, 2002, 46(1): 131 - 160.
[28] 安爱民,祁丽春,丑永新,等. 基于粒子群优化的溶解氧质量浓度支持向量回归机[J]. 北京工业大学学报,2016,42(9):1318 - 1323.
AN Aimin, QI Lichun, CHOU Yongxin, et al. Support vector regression using particle swarm optimization for dissolved oxygen concentration[J]. Journal of Beijing University of Technology, 2016, 42(9): 1318 - 1323. (in Chinese)