

doi:10.6041/j.issn.1000-1298.2021.03.017

# 基于无人机多时相植被指数的冬小麦产量估测

程千 徐洪刚 曹引波 段福义 陈震

(中国农业科学院农田灌溉研究所, 新乡 453002)

**摘要:** 通过无人机搭载多光谱相机,对不同水分亏缺条件下冬小麦多个生育期进行遥感监测,采用不同种类多光谱植被指数表征冬小麦的生长特征,分析了植被指数与冬小麦产量的相关关系,并利用多时相植被指数构建产量估测数据集,采用偏最小二乘回归、支持向量机回归和随机森林回归3种机器学习算法进行冬小麦产量估测。结果表明,随着冬小麦的生长,多个植被指数与产量的相关性不断增强,灌浆末期相关系数达到0.7,植被指数与产量的线性回归决定系数也达到最大。多时相植被指数反映了冬小麦生长的变化特征,进一步提高了冬小麦产量估测精度,采用开花期和灌浆初期的多时相植被指数进行估产比采用单个生育期的植被指数估测产量的精度高,采用偏最小二乘回归模型的估测精度 $R^2$ 提高约0.021,支持向量机回归模型 $R^2$ 提高约0.015,随机森林回归模型 $R^2$ 提高约0.051。采用灌浆末期的多时相植被指数,3种模型均有较高的估测精度,偏最小二乘回归模型估测精度最高时的 $R^2$ 、RMSE分别为0.459、1 822.746 kg/hm<sup>2</sup>,支持向量机回归模型估测精度最高时的 $R^2$ 、RMSE分别为0.540、1 676.520 kg/hm<sup>2</sup>,随机森林回归模型估测精度最高时的 $R^2$ 、RMSE分别为0.560、1 633.896 kg/hm<sup>2</sup>,本文数据集训练的随机森林回归模型估测精度最高,且稳定性更好。

**关键词:** 冬小麦; 产量估测; 多光谱植被指数; 无人机

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2021)03-0160-08

OSID:



## Grain Yield Prediction of Winter Wheat Using Multi-temporal UAV Based on Multispectral Vegetation Index

CHENG Qian XU Honggang CAO Yinbo DUAN Fuyi CHEN Zhen

(Farmland Irrigation Research Institute, Chinese Academy of Agricultural Sciences, Xinxiang 453002, China)

**Abstract:** Timely and accurate crop monitoring and grain yield prediction before harvest of winter wheat are helpful for accurate farmland management and decision-making. Aiming to explore the potential of multi-temporal vegetation indices (VIs) extracted from unmanned aerial vehicle (UAV) based multispectral images in the whole growth period of winter wheat and improve the grain yield prediction, a UAV platform carrying multispectral camera was employed to collect the high resolution images of the whole growth period of winter wheat under different water deficit states. Different kinds of multispectral VIs were used to characterize the growth characteristics of winter wheat and the correlations between VIs and winter wheat grain yield were analyzed. The multi-temporal VIs were collected to form the data set, which was used to train the machine learning algorithm. Three algorithms, including partial least squares regression (PLSR), support vector regression (SVR) and random forest regression (RFR) were used to predict the grain yield of winter wheat. The results showed that with the growth of winter wheat, the leaf area index (LAI) was changed basically as parabolic, indicating the useful of MTVI2 in remote sensing retrieval of LAI. Meanwhile, the correlation coefficient between multiple VIs and grain yield was continually increased to 0.7 at the end of the filling stage. The linear regression determination coefficient ( $R^2$ ) between VIs and grain yield also reached the maximum. Moreover, the accuracy of VIs forecasting grain yield was also continuously improved, because of the multi-temporal VIs reflecting the changing

收稿日期: 2020-11-01 修回日期: 2021-01-11

基金项目: 中央级公益性科研院所基本科研业务费专项(FIRI202002-03)、中国农业科学院重大产出培育项目和河南省科技研发专项(192102110095)

作者简介: 程千(1987—),男,助理研究员,博士,主要从事节水高效灌溉技术与装备研究,E-mail: qiangood526@126.com

通信作者: 陈震(1985—),男,助理研究员,博士,主要从事节水高效灌溉技术与装备研究,E-mail: chenchen@caas.cn

characteristics of winter wheat growth. The multi-temporal VIs at the flowering and early stage of filling had higher accuracy than the VIs at a single growth period. For instance, the  $R^2$  of PLSR was increased by about 0.021 and the  $R^2$  of SVR was increased by about 0.015 and the  $R^2$  of RFR was increased by about 0.051. For the multi-temporal vegetation index at the end of filling stage, different models had high estimation accuracy. The highest  $R^2$  and RMSE of PLSR were 0.459 and 1 822.746 kg/hm<sup>2</sup>, the highest  $R^2$  and RMSE of SVR were 0.540 and 1 676.520 kg/hm<sup>2</sup> and the highest  $R^2$  and RMSE of RFR were 0.560 and 1 633.896 kg/hm<sup>2</sup>, respectively. So the RFR trained in this data set had the highest estimation accuracy and better stability. These findings demonstrated that the proposed approach can improve the prediction accuracy of grain yield as well as achieve an efficient monitoring of crop growth. Under water deficit conditions, long-term water deficit had a great impact on the growth of winter wheat at the filling stage, in turn leading to a decline of winter wheat grain yield. In comparison with normal quantity of irrigation water, the long-term water deficit caused a decrease in winter wheat production by about 1/2.

**Key words:** winter wheat; grain yield prediction; multispectral vegetation index; unmanned aerial vehicle

## 0 引言

收获前,及时准确地估测农作物产量有助于相关粮食政策的调整及制定。遥感技术是监测作物生长状况的有效手段,遥感估产则是将遥感信息作为输入变量,通过建立遥感估产模型来估测作物产量。随着科技的发展,无人机能够以低成本和更实用的方式获取高时空分辨率的遥感数据,并将其应用于作物生长监测<sup>[1-6]</sup>和产量估测中<sup>[7-9]</sup>,弥补了卫星遥感运行周期长、空间分辨率低和受气象条件影响大等不足。

多光谱传感器包含的近红外波段能够较好地捕捉作物整个生育期内叶片结构变化产生的光谱反射特征,其与其他波段构建的植被指数包含更多的作物生长信息,有助于产量估测。通过建立植被指数与产量间的统计关系进行遥感估产的方法,简单易行,目前已有许多学者利用无人机平台搭载多光谱传感器对不同作物进行产量估测<sup>[6,10-13]</sup>。

在冬小麦生长阶段,冠层反射率在不断发生变化,冬小麦生殖生长阶段的光谱指数与产量具有更高的相关性,可更好地用来估测产量,如开花期<sup>[14]</sup>或灌浆初期<sup>[15]</sup>的光谱植被指数等。随着生长过程的延续,产量与单一时期光谱指数之间的相关性达到非常显著的水平,但是无法在单个时期内确定产量形成的过程。相反,由多个生育期生长信息构成的数据集能更好地反映作物生长变化过程,可以提供更多有用的信息,有利于提高算法的估测精度。文献<sup>[16-17]</sup>利用多个生育期的植被指数的累积值进行作物产量估测,提高了估测精度。本文尝试将新生育期的植被指数作为样本数据新的属性值添加到上一个生育期的数据集中,形成新的多时相植被指数数据集,从而对冬小麦产量进行估测。

本文采用无人机搭载多光谱传感器,对冬小麦多个生育期进行遥感监测,提取多种光谱植被指数,并利用多时相的植被指数构建数据集,训练机器学习算法,进行冬小麦产量的估测分析。

## 1 材料与方 法

### 1.1 试验区概况

试验区位于河南省新乡市七里营镇中国农业科学院新乡综合试验基地(113°45'38"N,35°8'10"E),该试验区地形为黄河北部冲积扇平原,海拔73 m,土壤类型为粘壤土。气候类型属于温带季风气候,四季分明,雨热同期,多年年平均气温14.5℃,年平均降水量560 mm左右,主要集中在6—9月,平均无霜期199 d,试验研究区位置见图1。本次研究共有3种灌溉水量处理(Irrigation treatment, IT):240 mm(IT1)、190 mm(IT2)和145 mm(IT3),每种灌水处理包含60个小区;试验选取了30个小麦品种,每个小区1个品种,随机分布种植,则每个灌水处理对应30个品种,重复两次,试验设计如图1所示。




图1 试验小区布置图

Fig. 1 Layout of the test area

### 1.2 无人机平台与遥感数据获取

采用大疆经纬 M210 型四旋翼无人机平台,无人机净质量 4.69 kg,最大承载质量 1.45 kg,续航时

间 20 min 左右。无人机搭载 MicaSense RedEdge - MX 型多光谱相机拍摄多光谱影像。多光谱相机质量 232 g, 图像尺寸 1 280 像素 × 960 像素, 具有蓝 (Blue, B, (475 ± 20) nm)、绿 (Green, G, (560 ± 20) nm)、红 (Red, R, (668 ± 10) nm)、红边 (Red-edge, RE, (717 ± 10) nm) 和近红外 (Near infrared, NIR, (840 ± 40) nm) 共 5 个通道。

冬小麦抽穗之后, 进入生殖生长阶段, 各器官营养逐步转化为籽粒的形成, 小麦叶片开始衰落, 此时虽然冠层光谱反射率不断降低, 但与产量的相关性逐步升高<sup>[12]</sup>。因此, 从冬小麦开花期到灌浆期, 选取多次采集的多光谱影像, 进行产量预测。具体采集日期为: 开花期 (S1, 2020 年 4 月 14 日)、灌浆初期 (S2, 2020 年 4 月 23 日)、灌浆中期 (S3, 2020 年 4 月 30 日) 和灌浆末期 (S4, 2020 年 5 月 10 日)。

影像采集时使用大疆 GSPRO 地面站对试验区覆盖范围规划航线自主飞行。为保证影像质量, 减少大气影响, 选择天气晴好、无云低风速且 11:00—14:00 时间段飞行。飞行高度 30 m, 影像重叠率为航向 85% 和旁向 80%, 地面空间分辨率为 2 cm。

### 1.3 数据处理

#### 1.3.1 影像预处理

采用 Pix4Dmapper 软件对无人机的多光谱影像进行拼接处理, 并导入每次飞行前后拍摄的校准板的影像进行辐射校正, 生成该试验区地物反射率的正射影像图。将正射影像图导入开源软件 QGIS, 进行几何校正、试验小区矢量文件制作、多光谱植被指数计算、各小区多光谱植被指数统计等, 得到各小区多光谱植被指数均值作为产量估测的输入变量。

#### 1.3.2 多光谱植被指数选取

目前已有多种多光谱植被指数用于作物产量估测研究, 如表 1 所示, 大致分为以下几类<sup>[18]</sup>: ①基于红波段和近红外波段运算的多光谱指数: 差异植被指数 (Difference vegetation index, DVI)、增强植被指数 (Enhanced vegetation index, EVI)、比率植被指数 (Ratio vegetation index, RVI)、改善简单比率指数 (Modified simple ratio, MSR)、归一化植被指数 (Normalized difference vegetation index, NDVI)、植被色素比率 (Plant pigment ratio, PPR)、结构不敏感色素指数 (Structure insensitive pigment index, SIPI) 和改进的非线性植被指数 (Modified nonlinear vegetation index, MNVI)。②优化土壤背景的红波段和近红外波段运算的多光谱指数: 土壤调节植被指数 (Soil-adjusted vegetation index, SAVI) 和优化土壤

调节植被指数 (Optimization of soil-adjusted vegetation index, OSAVI)。③利用红边波段特征的多光谱指数: 红边叶绿素指数 (Red-edge chlorophyll index, CI<sub>RE</sub>)、红边归一化植被指数 (Red-edge NDVI, NDVI<sub>RE</sub>)、改良叶绿素吸收率指数 (Modified chlorophyll absorption ratio index, MCARI) 和转化叶绿素吸收反射指数 (Transformed chlorophyll absorption reflectance index, TCARI)。④基于从绿波段到近红外波段光谱反射率曲线形状的指数: 三角植被指数 (Triangular vegetation index, TVI) 和改善三角植被指数 2 (Modified triangular vegetation index 2, MTVI2) 等。

表 1 植被指数计算公式

Tab. 1 Vegetation index calculation formula

植被指数	代数式	来源
DVI	$\rho_{\text{NIR}} - \rho_{\text{R}}$	文献[19]
EVI	$2.5 \frac{\rho_{\text{NIR}} - \rho_{\text{R}}}{\rho_{\text{NIR}} + 6\rho_{\text{R}} - 7.5\rho_{\text{B}} + 1}$	文献[20]
RVI	$\rho_{\text{NIR}}/\rho_{\text{R}}$	文献[21]
MSR	$\frac{\rho_{\text{NIR}}/\rho_{\text{R}} - 1}{\sqrt{\rho_{\text{NIR}}/\rho_{\text{R}} + 1}}$	文献[22]
NDVI	$\frac{\rho_{\text{NIR}} - \rho_{\text{R}}}{\rho_{\text{NIR}} + \rho_{\text{R}}}$	文献[23]
PPR	$\frac{\rho_{\text{C}} - \rho_{\text{B}}}{\rho_{\text{C}} + \rho_{\text{B}}}$	文献[24]
SIPI	$\frac{\rho_{\text{NIR}} - \rho_{\text{B}}}{\rho_{\text{NIR}} - \rho_{\text{R}}}$	文献[25]
MNVI	$\frac{1.5(\rho_{\text{NIR}}^2 - \rho_{\text{R}})}{\rho_{\text{NIR}}^2 + \rho_{\text{R}} + 0.5}$	文献[26]
SAVI	$\frac{\rho_{\text{NIR}} - \rho_{\text{R}}}{\rho_{\text{NIR}} + \rho_{\text{R}} + L} (1 + L) (L = 0.5)$	文献[27]
OSAVI	$\frac{\rho_{\text{NIR}} - \rho_{\text{R}}}{\rho_{\text{NIR}} - \rho_{\text{R}} + L} (L = 0.16)$	文献[28]
CI <sub>RE</sub>	$\frac{\rho_{\text{NIR}}}{\rho_{\text{RE}}} - 1$	文献[29]
NDVI <sub>RE</sub>	$\frac{\rho_{\text{NIR}} - \rho_{\text{RE}}}{\rho_{\text{NIR}} + \rho_{\text{RE}}}$	文献[30]
MCARI	$[\rho_{\text{RE}} - \rho_{\text{R}} - 0.2(\rho_{\text{RE}} - \rho_{\text{C}})]\rho_{\text{RE}}/\rho_{\text{R}}$	文献[31]
TCARI	$3[\rho_{\text{RE}} - \rho_{\text{R}} - 0.2(\rho_{\text{RE}} - \rho_{\text{C}})]\rho_{\text{RE}}/\rho_{\text{R}}$	文献[32]
TVI	$60(\rho_{\text{NIR}} - \rho_{\text{C}}) - 100(\rho_{\text{R}} - \rho_{\text{C}})$	文献[33]
MTVI2	$\frac{1.5[1.2(\rho_{\text{NIR}} - \rho_{\text{C}}) - 2.5(\rho_{\text{R}} - \rho_{\text{C}})]}{\sqrt{(2\rho_{\text{NIR}} + 1)^2 - (6\rho_{\text{NIR}} - 5\sqrt{\rho_{\text{R}}})} - 0.5}$	文献[18]

注:  $\rho_{\text{B}}$  为蓝波段反射率;  $\rho_{\text{C}}$  为绿波段反射率;  $\rho_{\text{R}}$  为红波段反射率;  $\rho_{\text{RE}}$  为红边波段反射率;  $\rho_{\text{NIR}}$  为近红外波段反射率。

### 1.4 数据分析方法

水分亏缺条件下冬小麦生长特征出现差异, 遥感影像的像元灰度变化能够反映生长特征的变化。通过多光谱植被指数评价水分亏缺条件下, 冬小麦生育期的生长差异, 并采用皮尔逊相关系数和决定系数评价不同生育期的多光谱植被指数与冬小麦产量的线性相关程度, 选择合适的生育期和植被指数

进行产量估测。

分别采用偏最小二乘回归 (Partial least squares regression, PLSR)、支持向量机回归 (Support vector regression, SVR)、随机森林回归 (Random forest regression, RFR) 等统计学习算法进行冬小麦产量估测; 并采用决定系数  $R^2$ 、均方根误差 (Root mean squared error, RMSE) 和平均绝对误差 (Mean absolute error, MAE) 等指标评价不同统计学习算法的估测精度。以上数据分析均使用 Python 语言中的 Scikit-learn<sup>[34]</sup> 机器学习包完成。

## 2 结果与分析

### 2.1 植被指数与产量相关性分析

不同生育期多光谱植被指数与冬小麦产量的相关系数如图 2 所示, 可以看出, 进入开花期后, 光谱指数与产量出现相关性, 随着冬小麦生长, 相关性逐渐增强, 灌浆末期多个植被指数与产量相关系数达到 0.7。灌浆期后大部分植被指数与产量呈正相关关系, 且植被指数之间相关性较强, 而 TCARI 和 SIPI 与产量及其他植被指数呈较强的负相关关系。

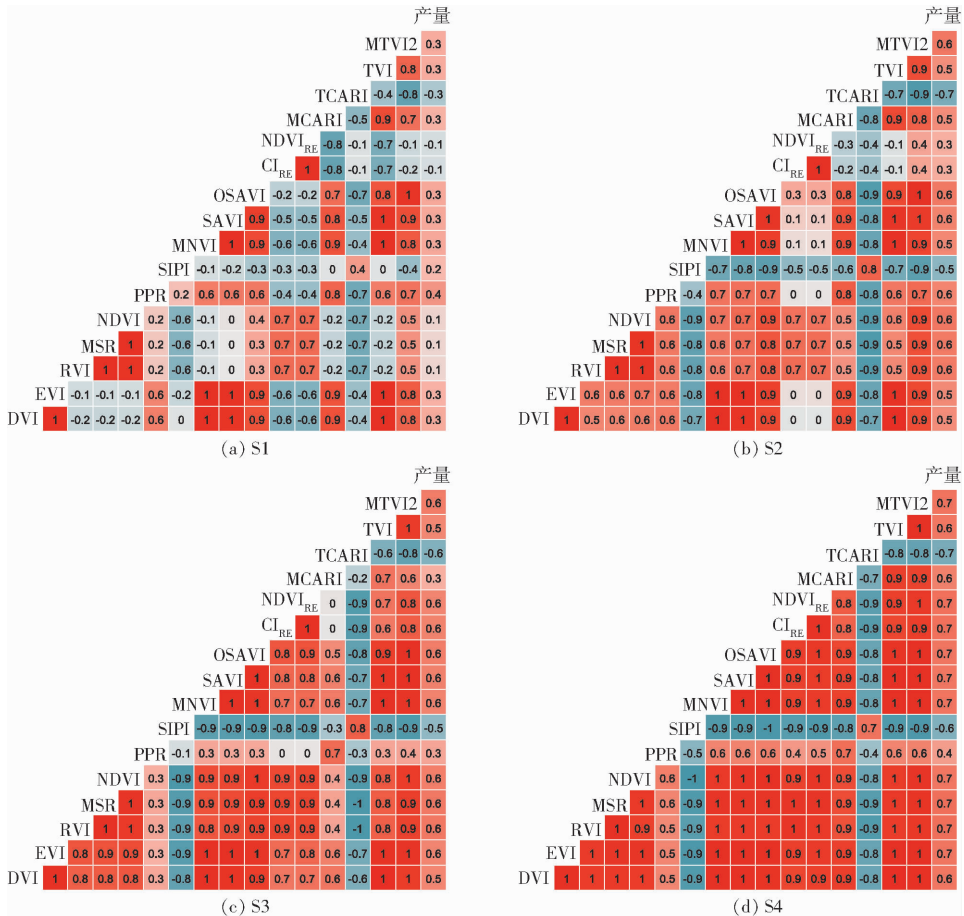


图 2 不同生育期植被指数之间以及植被指数与产量相关系数

Fig. 2 Correlation coefficient between vegetation index and yield in different growth stages

不同生育期多光谱植被指数与冬小麦产量的线性回归决定系数如表 2 所示, 可以看出, 随着冬小麦生殖阶段不断发展, 决定系数不断增大, 在灌浆末期达到最大。除 PPR 外, 其他植被指数均能在一定程度上反映产量的变化特征。可见本文选取的多光谱植被指数与冬小麦产量有较强的相关性, 能够用来估测冬小麦产量。

### 2.2 多时相植被指数估测产量

选取不同生育期多光谱植被指数, 采用 PLSR、SVR 和 RFR 等统计学习算法估测冬小麦产量, 结果如图 3 和表 3 所示。单时相时 (如 S1 或 S2 等), 将文中选取的 16 种植被指数分别作为自变量的 1 个

维度, 形成自变量向量, 即每个样本数据有 16 个属性值。当构建多时相植被指数数据集时 (如 S1 + S2 等), 将新生育期 (S2) 的 16 个植被指数合并到前 1 个生育期 (S1) 的自变量向量中, 形成新的多时相植被指数数据集, 每增加 1 个时相, 自变量向量增加 16 个维度, 即每个样本数据增加 16 个属性值。

在训练统计学习算法时, 为综合提高算法精度和泛化能力, 常采用交叉验证的方法, 由于试验有 3 种灌水处理, 为减少灌水处理对算法的影响, 保证数据分布的均匀性, 本文采用 10 次 5 折交叉验证, 取均值作为每种算法的评测指标值, 图 3 和表 3 中各评测指标值针对测试集的数据, 更能代表模型的估

表2 不同生育期植被指数与产量决定系数

Tab.2 Coefficient of determination between vegetation index and yield in different growth stages

多光谱植被指数	生育期			
	S1	S2	S3	S4
DVI	0.055	0.214	0.265	0.389
EVI	0.030	0.235	0.272	0.402
RVI	-0.035	0.362	0.388	0.450
MSR	-0.036	0.367	0.378	0.454
NDVI	-0.035	0.391	0.312	0.396
PPR	0.161	0.289	0.081	0.123
SIPI	0.013	0.243	0.173	0.320
MNVI	0.059	0.255	0.291	0.403
SAVI	0.062	0.294	0.301	0.399
OSAVI	0.065	0.371	0.319	0.401
CI <sub>RE</sub>	-0.036	0.054	0.297	0.449
NDVI <sub>RE</sub>	-0.036	0.045	0.279	0.446
MCARI	0.032	0.213	0.043	0.308
TCARI	0.061	0.414	0.327	0.423
TVI	0.051	0.204	0.261	0.388
MTVI2	0.051	0.385	0.338	0.419




图3 不同回归模型估测产量决定系数

Fig.3  $R^2$  of different regression models for grain yield prediction

测能力。

由图3和表3可知,当使用单个生育期的植被指数估测冬小麦产量时,由开花期到灌浆初期、灌浆中期和灌浆末期,不同算法的预测精度不断提高,这与植被指数与产量相关性变化规律一致。

使用生育期(S1+S2)的多时相植被指数比单个时相(S2)的植被指数估测产量的精度高,PLSR模

表3 不同回归模型估测产量统计分析

Tab.3 Validation statistics of different regression models for grain yield prediction

生育期	PLSR			SVR			RFR		
	$R^2$	RMSE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )	MAE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )	$R^2$	RMSE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )	MAE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )	$R^2$	RMSE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )	MAE/ ( $\text{kg}\cdot\text{hm}^{-2}$ )
S1	0.201	2 220.391	1 781.903	0.179	2 247.844	1 749.620	0.121	2 320.945	1 848.928 1
S2	0.405	1 914.504	1 540.814	0.400	1 919.624	1 554.365	0.397	1 924.217	1 515.201 9
S1+S2	0.426	1 880.096	1 521.957	0.415	1 896.352	1 503.371	0.448	1 840.500	1 446.817 9
S3	0.376	1 960.245	1 578.268	0.449	1 839.541	1 494.705	0.459	1 823.742	1 478.741 4
S1+S3	0.379	1 954.880	1 578.405	0.397	1 922.329	1 546.551	0.486	1 778.100	1 432.094 0
S2+S3	0.399	1 923.071	1 542.813	0.450	1 836.143	1 485.457	0.473	1 799.508	1 446.847 5
S1+S2+S3	0.414	1 898.935	1 540.370	0.460	1 823.038	1 457.225	0.495	1 760.515	1 411.200 5
S4	0.454	1 829.691	1 466.355	0.540	1 676.520	1 343.839	0.541	1 668.267	1 342.086 5
S1+S4	0.438	1 856.437	1 500.630	0.453	1 825.773	1 460.182	0.546	1 662.743	1 337.380 3
S2+S4	0.442	1 847.772	1 481.228	0.534	1 685.654	1 345.959	0.542	1 666.032	1 344.013 3
S3+S4	0.449	1 838.468	1 480.680	0.509	1 729.620	1 375.947	0.560	1 633.896	1 330.148 9
S1+S2+S4	0.459	1 822.746	1 489.984	0.508	1 735.896	1 371.800	0.544	1 665.379	1 337.373 3
S1+S3+S4	0.431	1 867.955	1 514.049	0.451	1 829.609	1 462.971	0.553	1 648.364	1 335.365 9
S2+S3+S4	0.455	1 827.151	1 466.980	0.513	1 724.261	1 370.410	0.549	1 655.438	1 345.695 7
S1+S2+S3+S4	0.448	1 841.018	1 500.714	0.500	1 748.636	1 387.222	0.546	1 662.556	1 346.837 9

型估测精度  $R^2$  提高约 0.021;SVR 模型  $R^2$  提高约 0.015;RFR 模型  $R^2$  提高约 0.051。同理,生育期(S1+S2+S3)的多时相植被指数比单个时相(S1或S2或S3)的植被指数估测产量的精度高,说明在灌浆末期(S4)到来前,这种数据集构建方式能够提高产量估测精度,对产量作出较好的提前估测。灌浆末期(S4)的植被指数与产量相关性更好,估测精度更高,此时构建的多时相植被指数,不同模型均有较高的估测精度。

对比3种统计学习算法,针对本文的数据集,当数据属性值增多时,PLSR估测能力低于SVR和RFR。PLSR模型针对生育期(S1+S2+S4)数据测试集的估测精度最高,平均  $R^2$  为 0.459, RMSE 为 1 822.746  $\text{kg}/\text{hm}^2$ ;SVR模型针对生育期S4数据测试集的估测精度最高,平均  $R^2$  为 0.540, RMSE 为 1 676.520  $\text{kg}/\text{hm}^2$ ;RFR模型针对生育期(S3+S4)数据测试集的估测精度最高,平均  $R^2$  为 0.560, RMSE 为 1 633.896  $\text{kg}/\text{hm}^2$ 。而且,RFR模型针对生

育期 S4 后不同时相植被指数组合的数据测试集,均表现出较高的估测精度。

图 4 为不同灌水处理时,不同品种冬小麦产量估测值与实测值对比,图中估测值针对某一生育期的全部数据样本,且估测模型分别选取估测精度最高的训练模型,PLSR 模型针对生育期 (S1 + S2 + S4),SVR 模型针对生育期 S4,RFR 模型针对生育期 (S3 + S4)。可以看出,3 种模型的估测值均反映不同灌溉处理条件下产量变化规律,并且 RFR 模型的估测值与实测值更为接近。

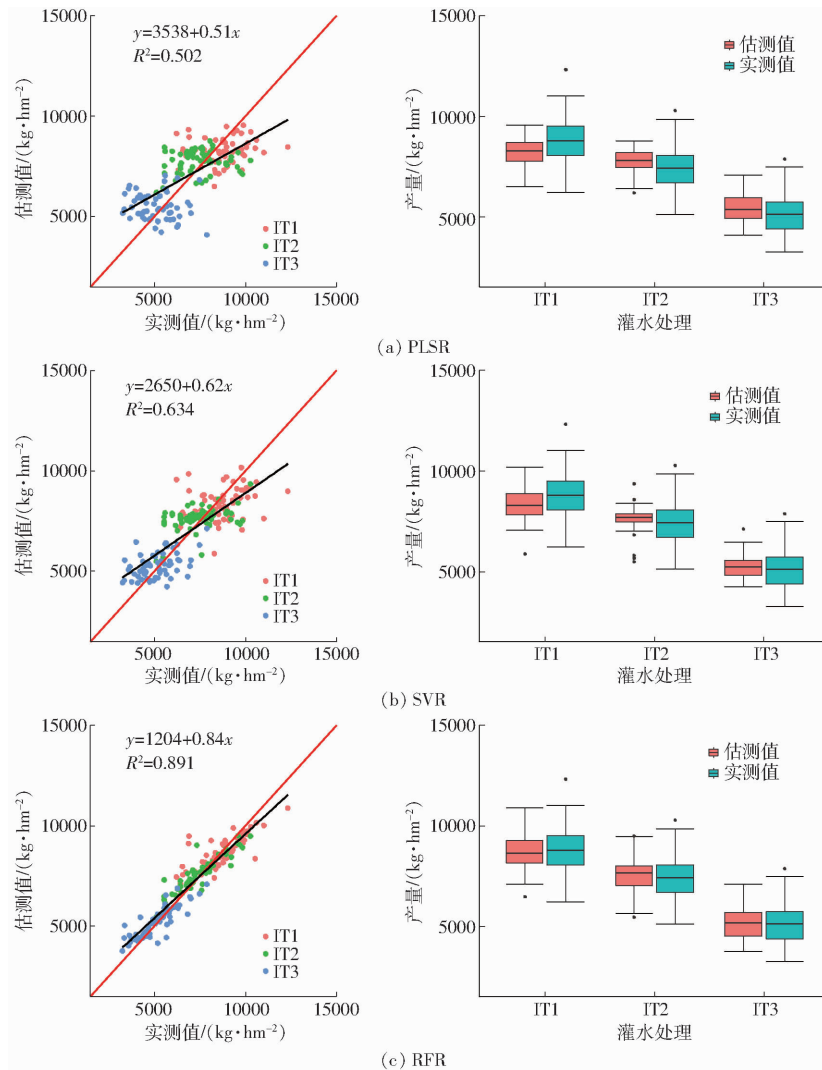


图 4 产量估测值与实测值对比

Fig. 4 Comparison of yield prediction values and measured values

### 3 讨论

本文将新生育期的植被指数作为新的属性值,添加到上一个生育期的数据集中,形成新的多时相植被指数数据集,提高了冬小麦产量估测精度,这与文献[11,13,17]的结论一致。而且文献[11]研究中同时使用了株高参数,并发现灌浆期株高比植被指数对冬小麦产量有更高的估测精度,说明不同类

正常灌溉处理 (IT1) 时,冬小麦产量平均达到  $8\ 700\ \text{kg}/\text{hm}^2$ ,水分亏缺处理 (IT2 和 IT3) 时,产量逐步降低,且水分亏缺严重时,产量下降较多,相比正常灌溉,冬小麦减产将近 1/2。对比冬小麦产量估测值与实测值,IT1 灌水处理时,估测值偏小;IT2 和 IT3 灌水处理时,估测值与实测值较为接近;但每个灌水处理条件下估测值的分布范围均比实测值的小。由于试验区冬小麦品种较多,同一灌水处理条件下,特别是正常灌水处理时,产量相差较大,使得数据分布较为分散。

型传感器获取的冠层参数,经过数据融合能进一步提高作物产量估测精度。可见,无论是多时相数据或多源数据,均提高了样本数据属性值的维度,有助于产量估测模型的训练。

采用统计学习模型进行回归预测时,样本数据的选择对模型的训练效果有较大影响,特别是样本数据量较小时,训练数据集的划分更为重要。交叉验证法适用于样本数量不大的情况,而且对模型偏

差和方差能够兼顾。本文采用  $P$  次  $K$  折交叉验证法,减小训练数据随机选取对模型预测精度带来的影响。 $P$  次为重复  $K$  折交叉验证的次数,通过  $P$  次重复减小随机误差,本文  $P$  选取 10。 $K$  折即把数据集划分为  $K$  等份,其中  $K-1$  份作为训练集,剩余 1 份作为测试集,由于样本总量为 180 个,单生育期时数据属性为 16 个,多时相时数据属性最多有 64 个,为保证不同生育期训练模型的偏差和方差均较低, $K$  值不宜过大或过小,本文  $K$  选取 5 作为数据集划分标准。

冬小麦产量构成因素较多,与多光谱植被指数之间存在较为复杂的非线性关系,PLSR 模型虽然包含了主成分分析过程,可以有效解决自变量之间的多个共线性问题,但当自变量与因变量之间存在复杂的关系时,其仍有较大的局限性。SVR 模型和 RFR 模型对复杂的非线性关系均有一定的回归能力,并且 RFR 模型具有更好的抗噪能力,本文冬小麦试验中有 30 个小麦品种,数据分布较为离散,针对灌浆末期的不同时相植被指数,RFR 模型均表现出较高的估测精度。但是当样本数据量过大,或者样本数据特征过多时,传统统计学习算法的预测能力将下降,需要训练更优秀的模型,如深度神经网络

模型等。

## 4 结论

(1)随着冬小麦的不断生长,植被指数与产量的相关性不断增强,灌浆末期多个植被指数与产量相关系数达到 0.7,基于此生育期植被指数估测冬小麦产量的精度也较高。

(2)采用多时相植被指数能进一步提高冬小麦产量的估测精度,采用冬小麦开花期和灌浆初期的多时相植被指数进行估产比采用单个生育期的植被指数估测产量的精度高,PLSR 模型估测决定系数  $R^2$  提高约 0.021,SVR 模型  $R^2$  提高约 0.015,RFR 模型  $R^2$  提高约 0.051。灌浆末期的多时相植被指数,3 种模型均有较高的估测精度。PLSR 模型估测精度最高时  $R^2$ 、RMSE 分别为 0.459、1 822.746 kg/hm<sup>2</sup>,SVR 模型估测精度最高时  $R^2$ 、RMSE 分别为 0.540、1 676.520 kg/hm<sup>2</sup>,RFR 模型估测精度最高时  $R^2$ 、RMSE 分别为 0.560、1 633.896 kg/hm<sup>2</sup>,相比之下,RFR 模型具有更好的稳定性。

(3)长时间的水分亏缺导致冬小麦产量下降,与正常灌溉水量相比,长时间的水分亏缺将造成冬小麦减产约 1/2,此时需及时制定灌溉计划。

## 参 考 文 献

- [1] 杨琦,叶豪,黄凯,等.利用无人机影像构建作物表面模型估测甘蔗 LAI[J].农业工程学报,2017,33(8):104-111. YANG Qi, YE Hao, HUANG Kai, et al. Estimation of leaf area index of sugarcane using crop surface model based on UAV image[J]. Transactions of the CSAE, 2017, 33(8): 104-111. (in Chinese)
- [2] 李长春,牛庆林,杨贵军,等.基于无人机数码影像的大豆育种材料叶面积指数估测[J/OL].农业机械学报,2017,48(8):147-158. LI Changchun, NIU Qinglin, YANG Guijun, et al. Estimation of leaf area index of soybean breeding materials based on UAV digital images[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8): 147-158. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170816&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170816&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2017.08.016. (in Chinese)
- [3] 赵静,杨焕波,兰玉彬,等.基于无人机可见光图像的夏季玉米植被覆盖度提取方法[J/OL].农业机械学报,2019,50(5):232-240. ZHAO Jing, YANG Huanbo, LAN Yubin, et al. Extraction method of summer corn vegetation coverage based on visible light image of unmanned aerial vehicle[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5): 232-240. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20190527&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190527&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2019.05.027. (in Chinese)
- [4] 陶惠林,徐良骥,冯海宽,等.基于无人机高光谱长势指标的冬小麦长势监测[J/OL].农业机械学报,2020,51(2):180-191. TAO Huilin, XU Liangji, FENG Haikuan, et al. Winter wheat growth monitoring based on UAV hyperspectral growth index[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 180-191. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=2002020&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002020&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2020.02.020. (in Chinese)
- [5] LIANG L, DI L, HUANG T, et al. Estimation of leaf nitrogen content in wheat using new hyperspectral indices and a random forest regression algorithm[J]. Remote Sensing, 2018, 10(12): 1940-1955.
- [6] 陈鹏,冯海宽,李长春,等.无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J].农业工程学报,2019,35(11):63-74. CHEN Peng, FENG Haikuan, LI Changchun, et al. Estimation of chlorophyll content in potato using fusion of texture and spectral features derived from UAV multispectral image[J]. Transactions of the CSAE, 2019, 35(11): 63-74. (in Chinese)
- [7] KANNING M, KUHLING I, TRAUTZ D, et al. High-resolution UAV-based hyperspectral imagery for LAI and chlorophyll estimations from wheat for yield prediction[J]. Remote Sensing, 2018, 10(12): 2000-2017.
- [8] LI B, XU X, ZHANG L, et al. Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162: 161-172.

- [9] MUHAMMAD A H, YANG Mengjiao, AWAIS R, et al. Time-series multispectral indices from unmanned aerial vehicle imagery reveal senescence rate in bread wheat[J]. *Remote Sensing*, 2018, 10(6): 809.
- [10] YUE J, YANG G, TIAN Q, et al. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 150: 226 – 244.
- [11] LI J, SIVAKUMAR A N V, BHATTA M, et al. Principal variable selection to explain grain yield variation in winter wheat from features extracted from UAV imagery[J]. *Plant Methods*, 2019, 15(1): 123 – 135.
- [12] MAIMAITIJIANG M, SAGAN V, SIDIKE P, et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. *Remote Sensing of Environment*, 2019, 237: 111599.
- [13] ZHOU X, ZHENG H B, XU X Q, et al. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 130: 246 – 255.
- [14] 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.
- [15] GONZALEZ D V, HERNANDEZ P, SOLIS I, et al. Using high-resolution hyperspectral and thermal airborne imagery to assess physiological condition in the context of wheat phenotyping[J]. *Remote Sensing*, 2015, 7(10): 13586 – 13605.
- [16] 韩文霆, 彭星硕, 张立元, 等. 基于多时相无人机遥感植被指数的夏玉米产量估算[J/OL]. *农业机械学报*, 2020, 51(1): 148 – 155.  
HAN Wenting, PENG Xingshuo, ZHANG Liyuan, et al. Summer maize yield estimation based on vegetation index derived from multi-temporal UAV remote sensing[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(1): 148 – 155. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20200116&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200116&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2020.01.016. (in Chinese)
- [17] WANG L, TIAN Y, YAO X, et al. Predicting grain yield and protein content in wheat by fusing multi-sensor and multi-temporal remote-sensing images[J]. *Field Crops Research*, 2014, 164: 178 – 188.
- [18] HABOUDANE D, MILLER J R, PATTEY E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture[J]. *Remote Sensing of Environment*, 2004, 90(3): 337 – 352.
- [19] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. *Remote Sensing of Environment*, 1979, 8(2): 127 – 150.
- [20] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. *Remote Sensing of Environment*, 2002, 83(1–2): 195 – 213.
- [21] PEARSON R L, MILLER L D. Remote mapping of standing crop biomass for estimation of the productivity of the short grass prairie, Pawnee National Grasslands, Colorado [C] // *Proceedings of the 8th International Symposium on Remote Sensing of Environment*, 1972: 1355 – 1379.
- [22] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications [J]. *Canadian Journal of Remote Sensing*, 1996, 22(3): 229 – 242.
- [23] ROUSE J W, HAAS R H, SCHELL J A, et al. Monitoring the vernal advancements and retro gradation of natural vegetation [M]. *Greenbelt: Texas A & M University, Remote Sensing Center*, 1974: 371.
- [24] METTERNICHT G. Vegetation indices derived from high-resolution airborne videography for precision crop management [J]. *International Journal of Remote Sensing*, 2003, 24(14): 2855 – 2877.
- [25] PEN U J, FILELLA I, LLORET P, et al. Reflectance assessment of mite effects on apple trees [J]. *International Journal of Remote Sensing*, 1995, 16(14): 2727 – 2733.
- [26] PENG G, PU R, BIGING G S, et al. Estimation of forest leaf area index using vegetation indices derived from Hyperion hyperspectral data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(6): 1355 – 1362.
- [27] HUETE A R. Soil influences in remotely sensed vegetation-canopy spectra [M] // ASRAR G. *Theory and applications of optical remote sensing*. New York: Wiley, 1989: 107 – 141.
- [28] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. *Remote Sensing of Environment*, 1996, 55(2): 95 – 107.
- [29] GITELSON A A, VINA A, CIGANDA V, et al. Remote estimation of canopy chlorophyll content in crops [J]. *Geophysical Research Letters*, 2005, 32(8): L08403.
- [30] GITELSON A, MERZLYAK M N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation [J]. *Journal of Plant Physiology*, 1994, 143(3): 286 – 292.
- [31] DAUGHTRY C S T, WALTHALL C L, KIM M S, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance [J]. *Remote Sensing of Environment*, 2000, 74(2): 229 – 239.
- [32] ZARCO-TEJADA P J, HABOUDANE D, MILLER J R, et al. Leaf chlorophyll a + b and canopy LAI estimation in crops using R – T models and hyperspectral reflectance imagery [C] // *Proceedings of the VII Congress of the European Society for Agronomy*. Cordoba, 2002.
- [33] BROGE N H, LEBLANC E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density [J]. *Remote Sensing of Environment*, 2001, 76(2): 156 – 172.
- [34] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: machine learning in Python [J]. *Journal of Machine Learning Research*, 2011, 12: 2825 – 2830.