

中图分类号: S532; S237 文献标识码: A 文章编号: 1672-3635(2023)06-0498-16

DOI: 10.19918/j.cnki.1672-3635.2023.06.003

栽培生理

基于无人机遥感影像的马铃薯产量估算

张斌斌, 魏峭嵘, 尹燕斌, 李若丹, 李双玉, 张 晶, 石 瑛*

(东北农业大学农学院, 黑龙江 哈尔滨 150030)

摘要: 马铃薯产量的精准预测对于保障粮食安全具有重要作用。为实现快速精准获取马铃薯产量信息, 研究利用无人机搭载可见光相机和多光谱相机, 分别于马铃薯现蕾期、初花期、盛花期和终花期进行无人机RGB和多光谱影像的采集, 并于收获期测定马铃薯产量。基于RGB和多光谱影像特征, 对马铃薯产量与RGB指数和植被指数分别进行相关性分析, 结合样本数量, 筛选出相关性最高的前五个光谱指数作为模型输入变量, 采用多元线性回归(Multiple linear regression, MLR)和随机森林(Random forest, RF)2种方法构建不同生育期和全生育期的估算模型, 并进行对比, 筛选出马铃薯产量估算的最优模型。通过RGB指数与植被指数结合可以提高马铃薯产量的估算效果, 并且多元线性回归模型的反演效果要优于随机森林模型。最终产量的估算效果从高到低分别是盛花期>全生育期>终花期>初花期>现蕾期, 马铃薯产量最优估算模型为盛花期以RGB指数与植被指数结合作为模型输入变量的MLR模型。测试集 R^2 和RMSE分别为0.77、0.64 kg/m²; 验证集 R^2 和RMSE分别为0.68、0.56 kg/m²。研究结果可为精准农业定量化研究提供技术支持。

关键词: 马铃薯; 无人机遥感; 产量; RGB指数; 植被指数

Potato Yield Estimation Based on UAV Remote Sensing Images

ZHANG Binbin, WEI Qiaorong, YIN Yanbin, LI Ruodan, LI Shuangyu, ZHANG Jing, SHI Ying*

(College of Agronomy, Northeast Agricultural University, Harbin, Heilongjiang 150030, China)

Abstract: The accurate prediction of potato yield plays an important role in ensuring food security. In order to obtain potato yield information quickly and accurately, an unmanned aerial vehicle (UAV) with a visible light camera and a multi-spectral camera were used to collect RGB and multi-spectral images of potatoes at the bud flower, early flowering, full flowering and late flowering stages, and potato yields were recorded at harvest time. Based on the RGB and multi-spectral image features, correlation analysis was conducted of potato yield with RGB index and vegetation index, respectively, and the top five spectral indices with the highest correlation were selected as model input variables by combining the sample size. Finally, multiple linear regression (MLR) and random forest (RF) were used to construct estimation models for different growth stages and the whole growth period, and were compared to select the optimal model for potato yield estimation. The combination of RGB index and vegetation index improved the estimation effect of potato yield, and the inverse effect of the multiple linear regression model was better than that of the random forest model. The estimated effect of final yield from high to low was: full flowering > whole growth period > late flowering > early

收稿日期: 2023-08-24

基金项目: 国家马铃薯现代农业产业技术体系建设专项(CARS-09-P10); 规模化种植与农业托管经营数字农服体系研发(2022ZX01A23); 黑龙江省马铃薯产业技术协同创新推广体系。

作者简介: 张斌斌(1999-), 男, 硕士, 研究方向为马铃薯栽培。

*通信作者(Corresponding author): 石瑛, 副研究员, 主要从事马铃薯遗传育种研究, E-mail: yshi@neau.edu.cn。

flowering > bud flower. The optimal model for estimating potato yield was the MLR model with the combination of RGB index and vegetation index as model input variables at full flowering. The test set R^2 and RMSE were 0.77 and 0.64 kg/m², respectively, whereas the validation set R^2 and RMSE were 0.68 and 0.56 kg/m², respectively. The results would provide technical support for accurate agriculture quantitative research.

Key Words: potato; UAV remote sensing; yield; RGB index; vegetation index

马铃薯作为中国第四大粮食作物,其产量的及时准确预报具有重要价值和现实意义,对于粮食政策制定和粮食安全至关重要^[1]。从微观角度看,在特定马铃薯栽培场地施肥、灌溉和施用农药,早期估算田间产量,并结合绘制田间产量空间变化图,在马铃薯田间管理中发挥着重要作用^[2-4]。同时,在马铃薯生育期间进行产量预测有助于提高马铃薯产量。从宏观角度看,高精度的马铃薯产量无损预测将能从大量有前途的基因型中快速有效地识别高产基因型^[5,6]。现阶段马铃薯产量遥感估测研究中,多是通过近地高光谱、无人机、卫星等遥感平台获取数据并将其与产量建立回归模型,达到马铃薯产量预测目的^[7]。

基于近地遥感平台的马铃薯产量反演由于其监测范围小、效率低等不足而受限。而基于卫星遥感平台的马铃薯监测手段可在短时间内获取大尺度、大范围的遥感信息,弥补了近地遥感监测短板。但其精度受制于大气中电磁以及云雾干扰,使得马铃薯产量反演结果产生误差,同时还受到卫星回访周期等因素制约。

近年来,无人机遥感平台被广泛应用于农业领域,其具有运行维护成本低、高效、灵活性高、作业周期短的特点,可有效弥补近地遥感平台人工采样导致的效率低以及卫星遥感数据由于射程远而引起的精度低等问题。Wan等^[8]利用无人机影像提取植被指数、冠层高度和冠层覆盖度,建立了精度较好的粮食产量预测模型。Guan等^[9]基于无人机多光谱影像、可见光影像为平台,提取归一化植被指数(Normalized difference vegetation index, NDVI)对水稻和小麦进行估产,其 R^2 分别为0.809和0.601。侯贵河^[10]使用决策树算法XGBoost和RF量化各特征参数在每个生育时期对最终产量的贡献度,构建多生育期参数加权的产量估算模型。结果表明,相比单

生育期估产模型,多生育期参数加权方法构建的估产模型可更加准确地反映玉米有机物质的积累过程,估产效果得到明显改进。王来刚等^[11]通过分析2005~2019年河南省遥感数据、气象数据、土壤水分等多源时空数据和小麦单产相关性,利用随机森林算法对各特征变量进行重要性排序,并构建冬小麦产量预测模型,结果表明遥感光谱特征(增强型植被指数、日光诱导叶绿素荧光和高程)和小麦产量呈高度正相关,且其特征重要性远大于其他因子。王鹏新等^[12]以条件植被温度指数(Vegetation temperature condition index, VTCI)和叶面积指数(Leaf area index, LAI)作为特征变量,使用随机森林回归确定了玉米各生育期特征变量的权重,最终构建得到加权VTCI和LAI与玉米产量的估产模型,研究表明基于随机森林回归的双变量估产模型效果最佳。陈浩^[13]利用试验数据将WOFOST模型参数本地化,通过集合卡尔曼滤波算法将试验区的遥感数据与作物模型进行同化,同时结合历史气象数据,预测夏玉米产量。结果表明作物模型结合无人机遥感技术同时基于历史气象数据的数据同化方法可以较为准确地预测夏玉米产量。朱婉雪等^[14]基于无人机遥感平台对冬小麦进行多时期遥感观测与估产,发现不同生长期冬小麦无人机遥感估产模型精度存在显著差异。同时,为提高作物产量预测精度,将无人机遥感数据与作物模型耦合^[15],或者融入其他农学参数,如作物株高^[16]、作物含水量^[17]、光合有效辐射利用效率^[18]、作物氮含量^[19],能有效改善模型预测精度。

前人研究大多以单生育期调整特征参数的方式来提升模型精度,而对于结合多种光谱指数进行全生育期预测作物产量的研究还较少。本研究以马铃薯为对象,基于无人机RGB影像和多光谱影像特征,结合地面实测产量值利用多元线性回归和随机

森林的方法分别构建马铃薯产量预测模型; 并将RGB指数和植被指数结合通过2种方法建立产量模型并验证, 最后筛选出最优估产模型, 为马铃薯产量评估提供理论基础。

1 材料与方法

1.1 试验地概况与试验设计

试验区位于东北农业大学向阳基地, 布设情况如图1所示。该地处于E 126°55', N 45°46', 属温带大陆性季风气候区, 全年平均降雨量569.1 mm, 年均日照时间4.4 h, 年均无霜期136 d, 平均气温3.5℃, 最高气温36℃, 最低气温-38℃。


试验地按品种('东农314' '东农317' '东农321' '东农326')划分为4个区域, 采用随机区组设计, 氮肥设3个处理(N 0、75、150 kg/hm²), 代号分别为N0、N1、N2, 重复3次(图1)。每个小区10行,

垄距80 cm, 株距25 cm, 行长5 m, 面积为36 m²。每小区去除边际效应2行留3行测产, 5行取样。品种顺序排列, 每个品种试验地总株数1 800株, 按每个切块重50 g计, 折合种薯重量约100 kg。每个品种总面积为324 m², 4个品种约1 296 m²。试验所用肥料为尿素(N 46%)、过磷酸钙(P₂O₅≥12%)、硫酸钾(K₂O 52%), 均为基肥, 一次施用。处理施肥情况如表1所示。

所有品种于2022年5月10日播种, 播种深度10 cm, 行距0.8 m, 密度6株/m²。采用乙草胺和噻草酮除草剂控制杂草, 并根据需要进行人工除草。

1.2 地面数据获取

2022年9月24日收获马铃薯, 在每个试验小区的测产区进行全部植株的收获、测量, 并人工去除块茎表面杂质, 统计块茎产量。最后根据种植密度, 换算为单位面积产量(kg/m²)。



注: 测试场地位置。带x的红圈为实时动态(RTK)GPS测量地面控制点(GCPs)位置; 黑色矩形代表试验材料取样位置; 紫色矩形代表品种'东农314'的种植位置; 蓝色矩形代表品种'东农317'的种植位置; 黄色矩形代表品种'东农321'的种植位置; 褐色矩形代表品种'东农326'的种植位置。

Note: Test site location. The red circle with x is the position of ground control points (GCPs) measured by real-time kinematic (RTK) GPS; and the black rectangle represents the sampling position of experimental materials. The purple rectangle represents the planting position of variety 'Dongnong 314'; the blue rectangle represents the planting position of variety 'Dongnong 317'; the yellow rectangle represents the planting position of variety 'Dongnong 321'; and the brown rectangle represents the planting position of variety 'Dongnong 326'.

图1 试验区布设情况

Figure 1 Deployment of the pilot area

表1 各处理施肥用量

Table 1 Fertilizer application rate of various treatments

处理 Treatment	施用量(kg/hm ²) Application rate (kg/ha)		
	N	P ₂ O ₅	K ₂ O
N0	0	138	75
N1	75	138	75
N2	150	138	75

1.3 无人机遥感影像采集

试验使用 Matrice 300 RTK 无人机(深圳市大疆创新科技有限公司)作为无人机遥感平台, 获取马铃薯遥感影像数据, 采集影像数据包括无人机多光谱航拍影像和无人机 RGB 航拍影像。无人机搭载的 RGB 相机为大疆禅思 P1(ZENMUSE P1) RGB 相机(深圳市大疆创新科技有限公司), 多光谱相机为 MS600 Pro 6 通道多光谱相机(长光禹辰信息技术有限公司与装备有限公司), 同时配备一块灰板, 具有固

定的反射率, 可以用来对多光谱影像进行辐射校正。MS600 Pro 多光谱相机参数及灰板对其中心波长的反射率如表 2 所示。

分别于马铃薯现蕾期(2022 年 6 月 22 日)、初花期(2022 年 7 月 6 日)、盛花期(2022 年 7 月 21 日)和终花期(2022 年 8 月 6 日)4 个关键生育时期进行无人机影像采集。其中, 无人机航线规划、拍照设置以及飞行控制所使用的均为 DJI Ground Station Pro APP(深圳市大疆创新科技有限公司)。影像数据采集时, 为减小光照对遥感影像影响, 选择在光照稳定、晴朗无云的天气条件下进行, 飞行时间选择上午 10:00~12:00。同时为更好地获取植株表型信息, 将航线高度设置为 15 m, 航向重叠度 80%, 旁向重叠度 70%, 等时间隔拍照。在此设置下, 无人机航速为 10.8 km/h, 拍照间隔为 1 s。对于多光谱影像获取时, 需要在飞机起飞之前, 对灰板进行拍照, 用于之后的辐射校正。

表2 MS600 Pro 多光谱相机参数及灰板对其中心波长的反射率

Table 2 MS600 Pro multispectral camera parameters and gray plate reflectivity to its central wavelength

波段序号 Band number	波段名称 Band name	中心波长(nm) Center wavelength	波宽(nm) Wave width	灰板反射率 Gray plate reflectance
1	蓝光	450	35	0.61
2	绿光	555	27	0.60
3	红光	660	22	0.60
4	红边	720	10	0.61
5	红边	750	10	0.61
6	近红外	840	30	0.60

1.4 无人机 RGB 影像处理

利用 Pix4Dmapper 对无人机 RGB 影像进行图像拼接。首先, 将相机按照固定航线拍摄的多幅图像与航拍影像 POS 数据以日期为索引导入图像数据处理软件 Pix4Dmapper 中。然后, 设置相关坐标系参数, 导入控制点坐标。利用在地块放置的地面控制点为特征, 实现影像与影像间地理坐标统一, 最后生成试验区域数字正射影像图。由于土壤背景会影响植物冠层反射光谱, 剔除土壤背景可提高建模估测精度^[20]。因此, 本试验在提取 RGB 指数前利用 ENVI 进行了土壤背景的剔除。

1.5 无人机多光谱影像处理

将采集的多光谱影像通过 Ysense Map 软件进行处理。处理步骤分为以下 3 步: (1) 通过影像内置 GPS 新建工程, 选择 5~10 组具有代表性图像, 在相机参数设置中实现空中三角测量、自动转点等工作, 最终输出虚拟相机参数, 将所有影像完成影像内定向、波段配准; (2) 通过空中三角测量、概略 DSM、单片正射影像、镶嵌正射影像完成影像拼接; (3) 利用飞行前拍摄的灰板照片, 通过辐射定标完成标定工作, 得到研究区具有真实地面反射率的遥感影像。同时, 在植被指数提取前利用

ENVI进行土壤背景剔除。

1.6 RGB 指数提取

将拼接好的RGB影像导入ENVI遥感图像处理平台，剔除土壤背景。在每个小区内，使用ROI(Region of Interest)工具标出位于测产区的矩形，避免边缘效应及在取样区取样时所造成的破坏性带来的影响。分别提取每个小区内部RGB波段DN值，用于RGB指数计算。为消除每次拍摄时光照不同带来的影响，对R波段、G波段和B波段的DN值，分别按照公式(1)~(3)进行归一化处理^[21]：

$$r = R / (R + G + B)$$

（1）

$$g = G / (R + G + B)$$

（2）

$$b = B / (R + G + B)$$

（3）

式中：R、G、B分别为RGB影像的DN值，r、g、b分别为影像归一化后的数值。基于前人研究，选取了12种常用RGB指数，用于马铃薯产量估测。RGB指数如表3所示。

1.7 多光谱植被指数提取

植被指数通常是两个或多个波段的光谱反射率的比值、线性或非线性组合，可以突出植被信息，广泛被用来反演各种植被参数^[27]。植被指数与

RGB指数提取类似，分别提取每个小区的冠层反射率。以测产区所划矩形内所有像素平均反射率作为该小区的平均冠层反射率，用于植被指数的计算。基于众多学者大量研究，选取10种常见的植被指数，用于估算马铃薯产量。植被指数公式和来源文献如表4所示。

表 3 RGB 指数汇总
Table 3 RGB index summary

RGB 指数 RGB index	计算公式 Formula	参考文献 Reference
r	$r = R / (R + G + B)$	[21]
g	$g = G / (R + G + B)$	
b	$b = B / (R + G + B)$	
VARI	$(g - r) / (g + r - b)$	[22]
GRVI	$(g - r) / (g + r)$	[23]
MGRVI	$(g^2 - r^2) / (g^2 + r^2)$	[24]
RGBVI	$(g^2 - r \times b) / (g^2 + r \times b)$	
EXG	$2g - r - b$	[21]
BGI	b / g	[25]
BRI	b / r	
GRI	g / r	
TGI	$-0.5[190(r - g) - 120(r - b)]$	[26]

表 4 植被指数汇总
Table 4 Definitions of vegetation indices

植被指数 Vegetation index	计算公式 Formula	参考文献 Reference
归一化植被指数(NDVI)	$NDVI = (NIR - RED) / (NIR + RED)$	[28]
绿色归一化植被指数(GNDVI)	$GNDVI = (NIR - Green) / (NIR + Green)$	[29]
土壤调节植被指数(OSAVI)	$OSAVI = 1.16(NIR - RED) / (NIR + RED + 0.16)$	[30]
修正叶绿素吸收反射率植被指数(MCARI)	$MCARI = [REG - RED - 0.2(REG - Green)]REG / RED$	[31]
改进的简单比值指数(MSR)	$MSR = (NIR / RED - 1) / (NIR / RED + 1)^{0.5}$	[32]
红边叶绿素指数(CI _{re})	$CI_{re} = NIR / REG - 1$	[33]
作物氮反射指数(NRI)	$NRI = (Green - RED) / (Green + RED)$	[23]
红边归一化植被指数(NDRE)	$NDRE = (NIR - REG) / (NIR + REG)$	[34]
红波段比值植被指数(RVI _{red})	$RVI_{red} = NIR / RED$	[35]
双波段增强植被指数(EV12)	$EV12 = 2.5(NIR - RED) / (NIR + 2.4RED + 1)$	[36]

1.8 数据分析方法

采用皮尔逊相关系数(Pearson correlation coefficient)来衡量产量与光谱指数间相关性。在相关系数基础上，从中选出显著相关且相关性较高

指数构建模型进行估测。

本试验中所使用统计模型为多元线性回归(Multiple linear regression, MLR)模型和随机森林(Random forest, RF)模型。其中多元线性回归模型

是一元回归模型的扩展,其基本原理与一元线性回归模型类似。但事实上,一种农学参数往往与多个因素相互联系,由多个自变量最优组合共同预测或估计因变量更符合实际。随机森林算法实质是多棵决策树组成的分类器,使用自助法重采样技术从总样本数据集里有放回地随机抽取 n 个样本数据集,分别构建 n 棵决策树。每棵决策树都为二叉树,遵循自上向下递归分裂原则和节点不纯度最小原则充分生长,直至满足分支停止规则后停止生长。最终,取森林包含所有决策树结果的平均作为随机森林回归模型结果。随机森林算法具有抗过拟合能力强、训练速度快、对输入数据包容度大等优点。

对于数据集的划分,从36个小区中,随机选取24个小区作为建模集,剩余12个小区作为验证集。在采用不同建模方法时均使用同一套建模集和验证集,以确保不同模型之间精度的可比性。

1.9 模型精度评价

对于构建好的模型,使用决定系数(R^2)、均方根误差(Root mean squared error, RMSE)进行分析,比较各模型表现,评价模型反演精度,以确定最优模型。其中, R^2 表示预测值与实测值的拟合程度, RMSE反映预测值与实测值偏离程度,一般而言,模型 R^2 越高, RMSE越低,表明该模型有更好的估测能力。两个统计指标计算公式如(4)~(5)所示。 R^2 为无量纲值, RMSE单位为 kg/m^2 。

$$R^2 = \frac{\sum_{i=1}^n (y_i^* - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n}} \quad (5)$$

式中: y_i 为实测值, y_i^* 为预测值, $\bar{y}$ 为实测值的平均值, n 为样本数量。

2 结果与分析

2.1 产量数据分析

产量数据集样本特征统计如表5所示。马铃薯不同施氮处理、不同品种以及不同品种在不同施氮处理下产量方差分析显示:N0、N1、N2处理间

产量差异不显著(图2a);‘东农317’与‘东农321’之间无显著差异,但与‘东农314’‘东农326’差异极显著(图2b);4个品种在不同施氮处理条件下产量均无显著差异(图2c)。

2.2 基于RGB影像特征估测产量

2.2.1 RGB指数与产量的相关性分析

计算得到现蕾期、初花期、盛花期、终花期不同试验处理下各小区12个RGB指数,与相对应小区产量组成数据集;并将产量与这4个时期提取的RGB指数结合组成全生育期数据集。利用全生育期、现蕾期、初花期、盛花期和终花期提取的RGB指数分别对产量进行相关性分析(图3)。


在5个生育期, g 、 $VARI$ 、 $GRVI$ 、 $MGRVI$ 、 $RGBVI$ 、 EXG 、 BRI 、 GRI 、 TGI 与产量均呈正相关关系; r 与产量呈负相关关系; b 与产量在全生育期、现蕾期和终花期呈正相关关系,但在初花期与盛花期呈负相关关系; BGI 与产量在全生育期、现蕾期、终花期呈正相关关系,但在初花期和盛花期呈负相关关系。在现蕾期, BRI 与产量相关系数最高,为0.50,在0.01水平上显著; r 、 b 与产量相关系数分别为-0.35和0.34,在0.05水平上显著;其余RGB指数与产量相关系数在0.01~0.26,相关关系不显著。在初花期, r 、 $VARI$ 、 $GRVI$ 、 $MGRVI$ 、 BRI 与产量的相关系数分别为-0.47、0.46、0.43、0.43、0.46,在0.01水平上显著; g 、 $RGBVI$ 、 EXG 、 GRI 、 TGI 与产量相关系数分别为0.37、0.38、0.37、0.42、0.36,在0.05水平上显著; b 、 BGI 与产量相关系数分别为-0.09、-0.30,但相关关系不显著。在盛花期, BGI 、 BRI 与产量相关系数分别为-0.37和0.38,在0.05水平上显著; b 与产量相关系数只有-0.07,相关性较差,相关关系不显著;其他RGB指数与产量相关关系均能达到在0.01水平上显著,其中 $MGRVI$ 与产量相关系数最高,为0.59。在终花期, r 、 $VARI$ 、 $GRVI$ 、 $MGRVI$ 、 BRI 、 GRI 与产量相关系数分别为-0.56、0.55、0.52、0.52、0.52、0.51,在0.01水平上显著; $RGBVI$ 与产量相关系数为0.37,在0.05水平上显著;其他5个RGB指数与产量相关性较差,相关系数在0.01~0.33,相关关系不显著。在全生育期,

仅有BRI与产量相关关系在0.01水平上达到显著水平，相关系数为0.50；r、b与产量相关关系在0.05水平上达到显著水平，相关系数分别为-0.35和0.34；而其余RGB指数与产量相关系数均在0.01~0.26，相关关系不显著。

综合来看，在全生育期利用RGB指数分析其与产量的相关性时，并无明显提高其相关关系。其中r、VARI、GRVI、MGRVI、BRI这5个RGB指数在绝大部分生育期与产量呈现出较强且稳定相关关系。


表5 马铃薯产量样本特征统计
Table 5 Statistics on characteristics of potato yield samples

样本量	最小值	最大值	均值	标准偏差	变异系数(%)
Sample size	Minimum	Maximum	Average	Standard deviation	Coefficient of variation
36	1.99	5.73	3.64	1.01	27.7



注：a.表示在不同施氮水平下马铃薯产量实测值。b.表示不同基因型产量实测值。c.表示在不同施氮处理下各基因型产量实测值。柱形图上不同小写字母和大写字母分别表示在0.05和0.01水平差异显著，处理平均值多重比较采用最小显著差数法(Least significant difference, LSD)。
Note: a. indicates the measured yield of potato at different nitrogen application rats. b. indicates the measured yield of different genotypes. c. indicates the measured yield of each genotype at different nitrogen application rates. Different lowercase and uppercase letters above the bars indicate significant differences at the 0.05 and 0.01 levels, respectively, as tested using least significant difference (LSD) method.

图2 不同品种在不同施氮处理条件下实测产量
Figure 2 Measured yield of different varieties at different nitrogen application rates



注：柱形图上*表示在0.05水平相关性显著，**表示在0.01水平相关性显著。下同。
Note: * over the bar graph indicates significant correlation at the 0.05 level and ** indicates significant correlation at the 0.01 level. The same below.

图3 不同生育期RGB指数与产量的相关系数
Figure 3 Correlation coefficient between RGB index and yield at different growth stages

2.2.2 基于RGB影像特征的马铃薯产量估算模型的构建与验证

基于RGB指数与产量相关性的分析，分别在马铃薯不同生育时期选择与产量相关性最高的前5个RGB指数作为自变量，以马铃薯产量为因变量，采用多元线性回归和随机森林算法分别构建现蕾期、初花期、盛花期、终花期以及全生育期的马铃薯产量预测模型。

同一建模方法在不同生育期对产量的反演效果存在差异，同一生育期中不同方法模型表现也不同(表6)。在现蕾期，对于建模集，MLR模型精度略低于RF模型；对于验证集，MLR模型的 R^2 、RMSE均高于RF模型；两种模型的决定系数均较小，无法准确预测产量。在初花期，MLR模型建模集和验证集各项评价指标均高于RF模型，MLR模型验证集决定系数为0.26，远小于0.66，无法对产量进行预测。在盛花期，RF模型建模集精度高于MLR模型，而验证集精度低于MLR模型，两种模型验证集 R^2 均较低，不能对产量进行预测。在终花期，对于建模集，RF模型 R^2 高于MLR模型，RMSE低于MLR模型；对于验证集，MLR模型 R^2 和RMSE均高于RF模型；两种模型验证集 R^2 分别为0.47、0.38，无法准确预测产量。在全生育期，RF模型建模集和

验证集精度均高于MLR模型，其中RF模型验证集 R^2 、RMSE分别为0.49、0.65 kg/m²，不能对产量进行预测。综合来看，在利用RGB指数预测产量时，各生育期两种模型均不能达到较好的预测效果。

从RF、MLR模型产量预测值和实测值的关系(图4、图5)可以观察到，两种模型对产量预测均具有较好的拟合效果，但对于较小值和较大值预测，两种模型在不同时期均出现不同程度高估和低估。

表6 基于RGB影像特征的产量反演模型构建和验证
Table 6 Construction and validation of yield inversion model based on RGB image features

建模方法	生育期	训练集		验证集	
Modeling	Growth stage	Training set		Validation set	
methodology		R^2	RMSE	R^2	RMSE
		(kg/m ²)		(kg/m ²)	
MLR	现蕾期	0.33	0.93	0.32	0.82
	初花期	0.39	0.89	0.26	0.85
	盛花期	0.67	0.67	0.44	0.74
	终花期	0.30	0.96	0.47	0.72
	全生育期	0.33	0.93	0.26	0.85
RF	现蕾期	0.45	0.77	0.31	0.75
	初花期	0.38	0.82	0.22	0.80
	盛花期	0.74	0.53	0.14	0.84
	终花期	0.46	0.77	0.38	0.71
	全生育期	0.69	0.58	0.49	0.65




图4 基于RGB影像特征的随机森林(RF)模型的产量预测值和实测值的关系

Figure 4 Relationship between predicted and measured yield values of a random forest (RF) model based on RGB image features




图5 基于RGB影像特征的多元线性回归(MLR)模型的产量预测值和实测值的关系

Figure 5 Relationship between predicted and measured yield values of a multiple linear regression (MLR) model based on RGB image features

2.3 基于多光谱影像特征估测产量

2.3.1 植被指数与产量的相关性分析

计算得到现蕾期、初花期、盛花期、终花期不同试验处理下各小区 10 个植被指数, 与相对应产量数据组成数据集; 并将产量与这 4 个时期提取的植被指数结合组成全生育期数据集。利用全生育期、现蕾期、初花期、盛花期和终花期提取的植被指数分别对产量进行相关性分析(图 6)。

在 5 个生育期, NDVI、MCARI、MSR、NRI、RVired 与产量均呈正相关关系; GNDVI、OSAVI、EV12 与产量在终花期呈现负相关关系, 在其他生育期呈正相关关系; CIRE 与产量在全生育期、现蕾期、盛花期呈正相关关系, 在初花期和终花期呈负相关关系; NDRE 与产量在全生育期、现蕾期、初花期呈正相关关系, 在盛花期和终花期呈负相关关系。在现蕾期, 所选植被指数与产量相关性均较差, 相关系数在 0.12~0.18, 相关关系不

显著。在初花期, NDVI、NRI 与产量的相关系数分别为 0.36、0.34, 在 0.05 水平上显著; 其余植被指数与产量相关系数在 -0.01~0.32, 相关关系不显著。在盛花期, NDVI、MSR、NRI、RVired 与产量相关系数分别为 0.47、0.46、0.57、0.45, 在 0.01 水平上显著; 其余植被指数与产量相关系数在 -0.01~0.27, 相关关系不显著。在终花期, NRI 与产量相关系数最高为 0.37, 在 0.05 水平上显著; 其余植被指数与产量相关系数在 -0.13~0.14, 相关关系不显著。在全生育期, 所有植被指数与产量相关性均较差, 相关系数在 0.12~0.18, 相关关系不显著(图 6)。

综合来看, 与利用 RGB 指数与产量进行相关性分析时产生的结果类似, 在全生育期植被指数与产量的相关性较差。其中 NDVI、GNDVI、MSR、NRI、RVired 在绝大部分生育期与产量表现出较好的相关性。




图 6 不同生育期植被指数与产量的相关系数

Figure 6 Correlation coefficient between vegetation index and yield at different growth stages

2.3.2 基于多光谱影像特征的马铃薯产量估算模型的构建与验证

基于植被指数与产量相关性分析, 分别在马铃薯不同生育时期选择与产量相关性最高的前 5 个植被指数作为自变量, 以产量为因变量, 采用多元线性回归和随机森林算法分别构建现蕾期、初

花期、盛花期、终花期以及全生育期的产量估算模型。

同一建模方法在不同生育期对产量的反演效果存在差异, 同一生育期中不同方法模型表现也不同(表 7)。在现蕾期, RF 模型建模集和验证集精度均高于 MLR 模型, 但两种模型的决定系数均

较低, 低于 0.66, 因此无法对产量进行预测。在初花期, MLR 模型建模集和验证集精度低于 RF 模型, MLR 模型和 RF 模型验证集 R^2 分别为 0.04、0.26, 无法对产量进行预测。在盛花期, 对于建模集, RF 模型比 MLR 模型精度更高; 对于验证集, RF 模型 R^2 和 RMSE 均小于 MLR 模型; 两者 R^2 均小于 0.66, 不能对产量进行预测。在终花期, MLR 模型建模集和验证集各项评价指标均大于或等于 RF 模型, 其中, MLR 模型验证集决定系数小于 0.66, 无法预测产量。在全生育期, 对于建模集, RF 模型精度较高; 对于验证集, MLR 模型精度较高; 但两种模型决定系数均较低, 无法实现对产量的预测。综合来看, 在利用植被指数进行产量的预测时, 各个生育期下两种方法模型均无法较好估算产量。

从 RF、MLR 模型产量预测值和实测值的关系 (图 7、图 8) 可以明显地观察到, RF 模型对于产量的预测值和实测值更加收敛于 1:1 线上, 而 MLR

模型产量预测值和实测值离散程度较高, 说明 RF 模型预测产量的效果更好。

表 7 基于多光谱影像特征的产量反演模型构建和验证
Table 7 Construction and validation of yield inversion models based on multi-spectral image features

建模方法 Modeling methodology	生育期 Growth stage	训练集 Training set		验证集 Validation set	
		R^2	RMSE	R^2	RMSE
		(kg/m ²)		(kg/m ²)	
MLR	现蕾期	0.14	1.08	0.01	0.99
	初花期	0.42	0.89	0.04	0.97
	盛花期	0.37	0.93	0.37	0.79
	终花期	0.44	0.90	0.17	0.90
	全生育期	0.14	1.08	0.29	0.84
RF	现蕾期	0.36	0.83	0.08	0.87
	初花期	0.64	0.63	0.26	1.01
	盛花期	0.53	0.71	0.32	0.75
	终花期	0.37	0.83	0.01	0.90
	全生育期	0.61	0.65	0.08	0.87




图 7 基于多光谱影像特征的随机森林 (RF) 模型的产量预测值和实测值的关系
Figure 7 Relationship between predicted and measured yield values of random forest (RF) models based on multi-spectral image features




图8 基于多光谱影像特征的多元线性回归(MLR)模型的产量预测值和实测值的关系

Figure 8 Relationship between predicted and measured yield values based on multiple linear regression (MLR) models with multi-spectral image features

2.4 基于RGB与多光谱影像特征结合估测产量

基于RGB指数、植被指数与产量的相关性分析, 分别在马铃薯不同生育时期选择与产量相关性最高的前10个光谱指数作为自变量, 以产量为因变量, 采用多元线性回归和随机森林算法分别构建现蕾期、初花期、盛花期、终花期以及全生育期的产量估算模型。

同一建模方法在不同生育期对产量的反演效果存在差异, 同一生育期中不同方法模型的表现也不同(表8)。在现蕾期, RF模型建模集和验证集精度均高于MLR模型, 其中RF模型验证集 R^2 为0.25、RMSE为0.78 kg/m², 无法准确预测产量。在初花期, 对于建模集, MLR模型的 R^2 和RMSE与RF模型大小几乎相等, 对于验证集, MLR模型 R^2 高于RF模型, RMSE略低于RF模型; 两种模型决定系数均低于0.66, 无法对产量进行预测。在盛花期,

MLR模型建模集 R^2 、RMSE分别为0.77、0.64 kg/m²略高于RF模型; MLR模型验证集精度远高于RF模型, 其中MLR模型验证集 R^2 为0.68, 表明可粗略预估产量; 而RF模型验证集 R^2 仅为0.23, 无法对产量进行预测。在终花期, 对于建模集, RF模型精度高于MLR模型; 对于验证集, MLR模型精度又高于RF模型, 但两种模型决定系数均小于0.66, 无法对产量进行预测。在全生育期, RF模型建模集和验证集精度均高于MLR模型, 其中RF模型验证集 R^2 为0.57, 无法准确预测产量。综合来看, 在利用RGB指数和植被指数结合进行产量预测时, 与利用RGB指数、植被指数进行产量预测时结果相同, 在各生育期两种模型均不能较好估算产量。从模型表现看, MLR模型在大部分生育期对产量都具有较好的预测效果, 而在现蕾期和全生育期, RF模型表现要优于MLR模型。

表8 基于RGB和多光谱影像特征结合的产量反演模型构建和验证

Table 8 Construction and validation of yield inversion models based on the combination of RGB and multi-spectral image features

建模方法 Modeling methodology	生育期 Growth stage	训练集 Training set		验证集 Validation set	
		R^2	RMSE(kg/m ²)	R^2	RMSE(kg/m ²)
MLR	现蕾期	0.38	0.97	0.22	0.88
	初花期	0.54	0.72	0.37	0.79
	盛花期	0.77	0.64	0.68	0.56
	终花期	0.50	0.93	0.42	0.76
	全生育期	0.38	0.97	0.14	0.92
RF	现蕾期	0.53	0.71	0.25	0.78
	初花期	0.54	0.71	0.11	0.85
	盛花期	0.75	0.52	0.23	0.79
	终花期	0.56	0.69	0.29	0.77
	全生育期	0.64	0.62	0.57	0.60

RF、MLR 模型产量预测值和实测值的关系 (图9、图10) 表明，RF 模型对于产量的预测值和实测值更加收敛于1:1线上，而 MLR 模型产量预测

值和实测值拟合效果较差，尤其是在全生育期，MLR 模型验证集产量预测值和实测值差距较大。说明 RF 模型预测产量的效果更好。




图9 基于RGB和多光谱影像特征结合的随机森林(RF)模型的产量预测值和实测值的关系

Figure 9 Relationship between predicted and measured yield values based on random forest (RF) model combing RGB and multi-spectral image features




图 10 基于 RGB 和多光谱影像特征结合的多元线性回归 (MLR) 模型的产量预测值和实测值的关系

Figure 10 Relationship between predicted and measured yield values based on multiple linear regression (MLR) model combining RGB and multi-spectral image features

3 讨 论

利用 RGB 指数与产量进行相关性分析, 发现在现蕾期 RGB 指数与产量相关性较低; 利用植被指数与产量进行相关性分析时, 发现在现蕾期和终花期植被指数与产量相关性较低。此结果符合预期, 因现蕾期马铃薯茎叶刚开始生长, 主要以自身营养状况为主, 体现在茎叶伸长, 叶片扩大; 终花期马铃薯茎叶开始衰老, 基部叶片自下而上逐渐衰老变黄, 马铃薯块茎停止生长转而淀粉积累。因此, 在马铃薯生育初期光谱信息和产量相关性表现较差^[37], 而生育后期地上茎叶枯黄, 冠层覆盖度降低, 使冠层信息提取易受土壤背景干扰, 造成冠层光谱信息无法充分表达与产量之间联系, 进而使光谱特征参数与产量的相关性偏低。此外, 马铃薯生育前期对养分需求不明显, 因此不同处理对马铃薯生长影响的差异不显著。因此, 在早期开发阶段实施的机器学习算法并不能准确反映

各种养分管理造成的产量差异。

同时基于光谱指数与产量相关性分析的结果, 筛选敏感参数, 利用无人机遥感数据估测马铃薯产量, 并在盛花期、终花期和全生育期取得了较好的反演精度。现蕾期与初花期, 估算模型精度较低, 可能是因现蕾期和初花期是马铃薯生长前期, 生物量值偏低, 对产量影响较小, 因此相比于生育后期, 利用马铃薯生育前期数据无法较好反演产量。Ramos 等^[38]、Uno 等^[39]和 García-Martínez 等^[40]分别利用出苗后 50 d、出苗后 66 d 和播种后 79 d 的无人机遥感数据成功预测了玉米产量, 说明开花期和灌浆期是预测玉米产量的最关键时期^[41]。而对于本研究构建的马铃薯产量估算模型结果来说, 在单一生育期间内, 利用盛花期无人机遥感数据将 RGB 和多光谱影像特征结合且采用 MLR 方法进行产量预测的精度最高, R^2 和 RMSE 分别为 0.68 和 0.56 kg/m²。相较于吴智超^[42]基于无人机数码影像覆盖度马铃薯最佳估产模型 R^2 提升了 0.20。由于盛花

期是马铃薯块茎重量快速增加的关键时期, 据此推断, 无人机遥感可以观测到这一时期马铃薯冠层的生长状况与产量高度相关。因此, 盛花期是预测马铃薯产量的理想候选阶段。同时, 通过全生育期预测马铃薯产量时, 并未达到预想效果, 全生育期产量估算模型预测效果介于生育前期和盛花期之间。综上所述, 基于无人机RGB和多光谱影像特征的马铃薯产量预测, 盛花期是最优选择。本研究虽然将RGB指数与植被指数结合作为模型输入变量的方式在盛花期和全生育期对产量的预测效果较好, 但与前人预测其他作物产量相比, 估算模型精度还存在差距。Yang等^[43]利用多时相数据提高了玉米产量估测精度, 最佳模型 R^2 和RMSE分别为0.93和0.77 t/hm²。Zhou等^[44]研究表明, 多时相光谱VIs与水稻籽粒产量的相关性高于单一阶段的VI。因此未来研究可尝试结合多个作物生长阶段无人机观测, 探究马铃薯产量预测的最佳无人机观测时段组合, 以期丰富作物生长信息, 从而缓解单时相观测偏差, 提升马铃薯产量估算模型精度。

本研究表明, 通过将无人机RGB和多光谱影像特征结合作为模型输入变量的方式可提高马铃薯估产模型精度。同时, 确定了马铃薯最佳估产时期为盛花期。其中, MLR模型估算效果最佳, 最优估产模型测试集 R^2 和RMSE分别为0.77、0.64 kg/m²; 验证集 R^2 和RMSE分别为0.68、0.56 kg/m²。

【参 考 文 献】

- [1] Pantazi X E, Moshou D, Alexandridis T, *et al.* Wheat yield prediction using machine learning and advanced sensing techniques [J]. Computers and Electronics in Agriculture, 2016, 121: 57–65.
- [2] Mourtzinis S, Arriaga F J, Balkcom K S, *et al.* Corn grain and stover yield prediction at R1 growth stage [J]. Agronomy Journal, 2013, 105(4): 1045–1050.
- [3] Schut A G T, Traore P C S, Blaes X, *et al.* Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites [J]. Field Crops Research, 2018, 221: 98–107.
- [4] Yang C, Everitt J H, Du Q, *et al.* Using high-resolution airborne and satellite imagery to assess crop growth and yield variability for precision agriculture [J]. Proceedings of the IEEE, 2012, 101(3): 582–592.
- [5] Elsayed S, Elhoweity M, Ibrahim H H, *et al.* Thermal imaging and passive reflectance sensing to estimate the water status and grain yield of wheat under different irrigation regimes [J]. Agricultural Water Management, 2017, 189: 98–110.
- [6] Yu N, Li L, Schmitz N, *et al.* Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform [J]. Remote Sensing of Environment, 2016, 187: 91–101.
- [7] 刘忠, 万炜, 黄晋宇, 等. 基于无人机遥感的农作物长势关键参数反演研究进展 [J]. 农业工程学报, 2018, 34(24): 60–71.
- [8] Wan L, Cen H, Zhu J, *et al.* Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the South of China [J]. Agricultural and Forest Meteorology, 2020, 291: 108096.
- [9] Guan S, Fukami K, Matsunaka H, *et al.* Assessing correlation of high-resolution NDVI with fertilizer application level and yield of rice and wheat crops using small UAVs [J]. Remote Sensing, 2019, 11(2): 112.
- [10] 侯贵河. 基于特征加权的玉米产量估算方法研究 [D]. 杨凌: 西北农林科技大学, 2022.
- [11] 王来刚, 郑国清, 郭燕, 等. 融合多源时空数据的冬小麦产量预测模型研究 [J]. 农业机械学报, 2022, 53(1): 198–204, 458.
- [12] 王鹏新, 齐璇, 李俐, 等. 基于随机森林回归的玉米单产估测 [J]. 农业机械学报, 2019, 50(7): 237–245.
- [13] 陈浩. 基于无人机遥感与WOFOST模型数据同化的夏玉米产量估计 [D]. 杨凌: 西北农林科技大学, 2021.
- [14] 朱婉雪, 李仕冀, 张旭博, 等. 基于无人机遥感植被指数优选的田块尺度冬小麦估产 [J]. 农业工程学报, 2018, 34(11): 78–86.
- [15] Kim M, Ko J, Jeong S, *et al.* Monitoring canopy growth and grain yield of paddy rice in South Korea by using the GRAMI model and high spatial resolution imagery [J]. GIScience and Remote Sensing, 2017, 54(4): 534–551.
- [16] Luo S, Wang C, Xi X, *et al.* Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation [J]. Ecological Indicators, 2017, 73: 378–387.
- [17] Cozzolino D, Fassio A, Gimenez A. The use of near-infrared reflectance spectroscopy (NIRS) to predict the composition of

- whole maize plants [J]. *Journal of the Science of Food and Agriculture*, 2001, 81(1): 142–146.
- [18] Tewes A, Schellberg J. Towards remote estimation of radiation use efficiency in maize using UAV-based low-cost camera imagery [J]. *Agronomy*, 2018, 8(2): 16.
- [19] Serrano L, Filella I, Penuelas J. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies [J]. *Crop Science*, 2000, 40(3): 723–731.
- [20] 陈鹏飞, 梁飞. 基于低空无人机影像光谱和纹理特征的棉花氮素营养诊断研究 [J]. *中国农业科学*, 2019, 52(13): 2220–2229.
- [21] Woebbecke D M, Meyer G E, Von Bargen K, *et al.* Color indices for weed identification under various soil, residue, and lighting conditions [J]. *Transactions of the ASAE*, 1995, 38(1): 259–269.
- [22] Gitelson A A, Kaufman Y J, Stark R, *et al.* Novel algorithms for remote estimation of vegetation fraction [J]. *Remote Sensing of Environment*, 2002, 80(1): 76–87.
- [23] Tucker C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. *Remote Sensing of Environment*, 1979, 8(2): 127–150.
- [24] Bendig J, Yu K, Aasen H, *et al.* Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2015, 39: 79–87.
- [25] Zarco-Tejada P J, Berjón A, López-Lozano R, *et al.* Assessing vineyard condition with hyperspectral indices: leaf and canopy reflectance simulation in a row-structured discontinuous canopy [J]. *Remote Sensing of Environment*, 2005, 99(3): 271–287.
- [26] Hunt Jr E R, Doraiswamy P C, McMurtrey J E, *et al.* A visible band index for remote sensing leaf chlorophyll content at the canopy scale [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2013, 21: 103–112.
- [27] 张峰, 吴炳方, 刘成林, 等. 利用时序植被指数监测作物物候的方法研究 [J]. *农业工程学报*, 2004(1): 155–159.
- [28] Rouse J W, Haas R H, Schell J A, *et al.* Monitoring vegetation systems in the Great Plains with ERTS [J]. *NASA Spec Publ*, 1974, 351(1): 309.
- [29] Gitelson A A, Kaufman Y J, Merzlyak M N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS [J]. *Remote Sensing of Environment*, 1996, 58(3): 289–298.
- [30] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation indices [J]. *Remote Sensing of Environment*, 1996, 55(2): 95–107.
- [31] Haboudane D, Miller J R, Tremblay N, *et al.* Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture [J]. *Remote Sensing of Environment*, 2002, 81(2–3): 416–426.
- [32] 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.
- [33] Gitelson A A, Viña A, Arkebauer T J, *et al.* Remote estimation of leaf area index and green leaf biomass in maize canopies [J]. *Geophysical Research Letters*, 2003, 30(5): 1248.
- [34] Fitzgerald G J, Rodriguez D, Christensen L K, *et al.* Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments [J]. *Precision Agriculture*, 2006, 7: 233–248.
- [35] Schuerg A C, Capelle G A, Di Benedetto J A, *et al.* Comparison of two hyperspectral imaging and two laser-induced fluorescence instruments for the detection of zinc stress and chlorophyll concentration in bahia grass (*Paspalum notatum* Flugge) [J]. *Remote Sensing of Environment*, 2003, 84(4): 572–588.
- [36] Jiang Z, Huete A R, Didan K, *et al.* Development of a two-band enhanced vegetation index without a blue band [J]. *Remote Sensing of Environment*, 2008, 112(10): 3833–3845.
- [37] Széles A V, Megyes A, Nagy J. Irrigation and nitrogen effects on the leaf chlorophyll content and grain yield of maize in different crop years [J]. *Agricultural Water Management*, 2012, 107: 133–144.
- [38] Ramos A P M, Osco L P, Furuya D E G, *et al.* A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices [J]. *Computers and Electronics in Agriculture*, 2020, 178: 105791.
- [39] Uno Y, Prasher S O, Lacroix R, *et al.* Artificial neural networks to predict corn yield from Compact Airborne Spectrographic Imager data [J]. *Computers and Electronics in Agriculture*, 2005, 47(2): 149–161.

(下转第 535 页)

- 56(3): 383–394.
- [16] Li W, Lee S Y, Cho Y J, *et al.* Mediation of induced systemic resistance by the plant growth-promoting rhizobacteria *Bacillus pumilus* S2-3-2 [J]. *Molecular Biology Reports*, 2020, 47(11): 8429–8438.
- [17] 朱杰, 程亮, 张纲, 等. 樱桃叶斑病生防菌株萎缩芽孢杆菌菌株 QH-588 的筛选鉴定 [J]. *南方农业学报*, 2021, 52(11): 3022–3033.
- [18] Liu D, Li K, Hu J, *et al.* Biocontrol and action mechanism of *Bacillus amyloliquefaciens* and *Bacillus subtilis* in soybean phytophthora blight [J]. *International Journal of Molecular Sciences*, 2019, 20(12): 2908.
- [19] Wang Z, Li Y, Zhuang L, *et al.* A rhizosphere-derived consortium of *Bacillus subtilis* and *Trichoderma harzianum* suppresses common scab of potato and increases yield [J]. *Computational and Structural Biotechnology Journal*, 2019, 17: 645–653.
- [20] Cui L, Yang C, Wang Y, *et al.* Potential of an endophytic bacteria *Bacillus amyloliquefaciens* 3-5 as biocontrol agent against potato scab [J]. *Microbial Pathogenesis*, 2022, 163: 105382.
- [21] 王鹏程, 金光辉, 张春雨, 等. 不同生防菌剂组合及施用方式对马铃薯疮痂病的防治效果及促生作用 [J]. *西南农业学报*, 2022, 35(4): 797–803.
-
- (上接第 513 页)
- [40] García-Martínez H, Flores-Magdaleno H, Ascencio-Hernández R, *et al.* Corn grain yield estimation from vegetation indices, canopy cover, plant density, and a neural network using multispectral and RGB images acquired with unmanned aerial vehicles [J]. *Agriculture*, 2020, 10(7): 277.
- [41] Ji Z, Pan Y, Zhu X, *et al.* Prediction of crop yield using phenological information extracted from remote sensing vegetation index [J]. *Sensors*, 2021, 21(4): 1406.
- [42] 吴智超. 基于无人机数码和高光谱影像的马铃薯生物量及产量估算 [D]. 焦作: 河南理工大学, 2020.
- [43] Yang B, Zhu W, Rezaei E E, *et al.* The optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing [J]. *Remote Sensing*, 2022, 14(7): 1559.
- [44] 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.