

doi:10.6041/j.issn.1000-1298.2023.07.019

基于无人机 RGB 影像的马铃薯植株钾含量估算

马彦鹏¹ 边明博¹ 樊意广¹ 陈志超² 杨贵军¹ 冯海宽^{1,3}(1. 北京市农林科学院信息技术研究中心, 北京 100097; 2. 河南理工大学测绘与国土信息工程学院, 焦作 454000;
3. 南京农业大学国家信息农业工程技术中心, 南京 210095)

摘要: 马铃薯植株钾含量(Plant potassium content, PKC)是监测马铃薯营养状况的重要指标, 快速准确地获取马铃薯植株钾含量对田间施肥和生产管理具有指导意义。基于无人机遥感平台搭载 RGB 传感器分别获取马铃薯块茎形成期、块茎增长期和淀粉积累期的 RGB 影像, 并实测马铃薯植株钾含量。首先利用各个生育期的 RGB 影像提取每个小区冠层平均光谱和纹理特征。然后分别基于冠层光谱和纹理特征构建植被指数和纹理指数(NDTI、RTI 和 DTI), 并与实测 PKC 进行相关性分析。最后利用多元线性回归(Multiple linear regression, MLR)、偏最小二乘(Partial least squares regression, PLSR)和人工神经网络(Artificial neural networks, ANN)构建马铃薯 PKC 估算模型。结果表明:各生育期 NDTI、RTI 和 DTI 与马铃薯 PKC 相关性均高于单一纹理特征, 植被指数结合纹理指数均能提高模型的可靠性和稳定性, MLR 和 PLSR 构建的估算模型精度均优于 ANN。本研究可为马铃薯 PKC 监测提供科学参考。

关键词: 马铃薯; 植株钾含量; 纹理指数; RGB 影像; 冠层光谱特征

中图分类号: S25 文献标识码: A 文章编号: 1000-1298(2023)07-0196-08

OSID:



Estimation of Potassium Content of Potato Plants Based on UAV RGB Images

MA Yanpeng¹ BIAN Mingbo¹ FAN Yiguang¹ CHEN Zhichao² YANG Guijun¹ FENG Haikuan^{1,3}

(1. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

2. School of Geomatics and Land Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China

3. National Engineering and Technology Center for Information Agriculture, Nanjing Agricultural University, Nanjing 210095, China)

Abstract: Plant potassium content (PKC) of potato plants is an important indicator for monitoring potato nutrition status. Obtaining PKC quickly and accurately has guiding significance for field fertilization and production management. RGB images of potato plants during the tuber formation period, tuber growth period, and starch accumulation period were obtained by using an unmanned aerial vehicle (UAV) remote sensing platform equipped with an RGB sensor, and PKC was measured. Firstly, the average spectral and texture features of each plot were extracted from the RGB images of each growth period. Then vegetation indices and texture indices (NDTI, RTI, and DTI) were constructed based on the spectral and texture features of the canopy, and their correlations with the measured PKC were analyzed. Finally, multiple linear regression (MLR), partial least squares regression (PLSR), and artificial neural networks (ANN) were used to construct models for estimating potato PKC. The results showed that the correlations between NDTI, RTI, DTI and PKC were higher than those of single texture features during each growth period. Combining vegetation and texture indices can improve the reliability and stability of the model. MLR and PLSR models were superior to ANN. The research result can provide scientific references for monitoring PKC in potato plants.

Key words: potato; plant potassium content; texture index; RGB images; canopy spectral features

收稿日期: 2023-04-03 修回日期: 2023-05-08

基金项目: 黑龙江省揭榜挂帅科技攻关项目(2021ZXJ05A05)和国家自然科学基金项目(41601346)

作者简介: 马彦鹏(1997—), 男, 实习研究员, 主要从事农业定量遥感研究, E-mail: mayanpeng2022@163.com

通信作者: 冯海宽(1982—), 男, 高级工程师, 主要从事农业定量遥感研究, E-mail: fenghaikuan123@163.com

0 引言

马铃薯是重要的薯类作物,可以粮菜兼用,在我国广泛种植^[1]。马铃薯是喜钾作物,钾含量会直接影响马铃薯产量、株高、茎粗、叶面积和生物量等^[2-3]。因此快速准确地获取马铃薯植株钾含量(Plant potassium content, PKC)对监测马铃薯生长发育状况具有重要意义。传统测量 PKC 的方法以田间破坏性取样为主,测量成本高且费时费力,难以大面积推广使用。无人机遥感技术机动性强,可以用于农作物长势监测、产量估算和病虫害监测等,使田间生产管理更加高效便捷^[4-6]。基于无人机遥感平台可以搭载 RGB、多光谱和高光谱传感器^[7-8]。

LU 等^[9]基于无人机高光谱传感器利用非负矩阵分解提取植被光谱,建立偏最小二乘回归(Partial least squares regression, PLSR)模型。结果表明,绿光带和红边带对水稻植株钾积累量估算有显著贡献。THOMSON 等^[10]研究发现利用无人机高光谱传感器反射率建立的 PLSR 模型可以有效估算森林植物叶片钾含量。SEVERTSON 等^[11]利用无人机多光谱和高光谱反射率有效识别了缺钾油菜。以上研究主要集中在高光谱传感器上,高光谱虽然能获取更多的光谱信息,但因其价格昂贵,处理过程复杂限制了它在农业生产中的应用。RGB 相机传感器虽然只能获取 3 个波段的光谱信息,但因其可以获取高分辨率影像,而且价格便宜,数据处理过程较为简单,成为广受关注的数据获取方式。

樊意广等^[12]基于无人机 RGB 相机传感器利用多元线性回归(Multiple linear regression, MLR)、BP 神经网络和 Lasso 回归结合冠层光谱特征模型有效估算了马铃薯植株氮含量,结果表明 MLR 构建的模型最优。刘杨等^[13]基于无人机 RGB 影像利用 MLR、支持向量机和人工神经网络(Artificial neural networks, ANN)结合植被指数估算马铃薯地上生物量,结果表明各生育期利用 MLR 方法构建的马铃薯地上生物量估算模型效果最佳。陶惠林等^[14]基于无人机 RGB 影像有效估算了冬小麦生物量。上述研究结果表明利用无人机 RGB 相机传感器可以有效估算作物氮素含量和生物量,但是仅利用影像的光谱信息构建的模型容易出现模型精度饱和现象。纹理信息通过像素灰度分布变化来反映目标与环境之间的空间关系,可以提供新的冠层信息^[15-16],在作物生长监测中发挥重要作用^[17-18],有学者提出引入图像的纹理信息结合光谱信息构建模型。

LU 等^[19]从无人机 RGB 影像中分别提取光谱信息和纹理信息估算水稻植株钾积累量,结果表明

光谱信息和纹理信息可以准确估算水稻植株钾积累量,两者融合能够进一步提高精度。ZHENG 等^[20]获取水稻关键生育期冠层多光谱图像,将提取的纹理特征归一化结合植被指数建模估算水稻地上生物量,结果表明,与单独使用光谱信息相比,归一化纹理信息与光谱信息结合显著提高了水稻生物量估算的准确性。MA 等^[21]利用棉花收获前冠层 RGB 影像监测棉花产量,表明从无人机高分辨率 RGB 影像中提取的植被指数和纹理特征与棉花产量显著相关,且植被指数结合纹理特征估算棉花产量效果最好。马铃薯的生长发育状况与上述作物不同,前期茎叶生长旺盛,但是到生长后期地上干物质不断向地下转移,地上叶片和茎开始死亡。基于无人机 RGB 影像提取植被指数和灰度共生矩阵(Gray-level co-occurrence matrix, GLCM)纹理特征可以提高高覆盖度下估算马铃薯地上生物量的准确性^[22],钾与氮素和生物量机理不同,已有的研究方法是否适用于马铃薯 PKC 监测还有待进一步研究。

因此,本研究以无人机遥感平台搭载 RGB 传感器获取马铃薯 3 个关键生育期的 RGB 影像,并提取各个生育期的冠层光谱特征和纹理信息,结合地面实测的 PKC 数据,采用 3 种不同的方法对每个生育期马铃薯 PKC 进行建模和验证,探究光谱特征结合纹理信息估算马铃薯 PKC 的适用性。

1 材料与方法

1.1 实验设计

实验于 2019 年在北京市昌平区小汤山镇国家精准农业研究示范基地开展。采用的马铃薯品种为 Z1(中薯 5)和 Z2(中薯 3)。共设 3 个实验区,每个实验区 3 个重复。P 区(密度实验区)设置 3 个密度水平($T_0: 60\ 000\ \text{株}/\text{hm}^2$; $T_1: 72\ 000\ \text{株}/\text{hm}^2$; $T_2: 84\ 000\ \text{株}/\text{hm}^2$); N 区(氮肥实验区)设置 4 个氮肥水平($N_0: 0\ \text{kg}/\text{hm}^2$; $N_1: 244.65\ \text{kg}/\text{hm}^2$; $N_2: 489.15\ \text{kg}/\text{hm}^2$; $N_3: 733.5\ \text{kg}/\text{hm}^2$); K 区(钾肥实验区)设置 3 个钾肥水平($K_0: 0\ \text{kg}/\text{hm}^2$; $K_1: 970\ \text{kg}/\text{hm}^2$; $K_2: 1\ 941\ \text{kg}/\text{hm}^2$)。P 区和 N 区钾肥水平均为 $K_1: 970\ \text{kg}/\text{hm}^2$ 。共 48 个小区(图 1),每个小区面积为 $5\ \text{m} \times 6.5\ \text{m}$ 。

1.2 无人机 RGB 影像获取及预处理

采用大疆精灵 4Pro 无人机遥感平台,分别在块茎形成期、块茎增长期和淀粉积累期选择晴朗无云的天气,在光照强度稳定的 12:00—14:00 获取 RGB 影像。表 1 为无人机飞行参数设置。飞行结束后将图像导入三维建模软件 Agisoft PhotoScan Professional(64 bit)生成每个生育期数字正射影像。

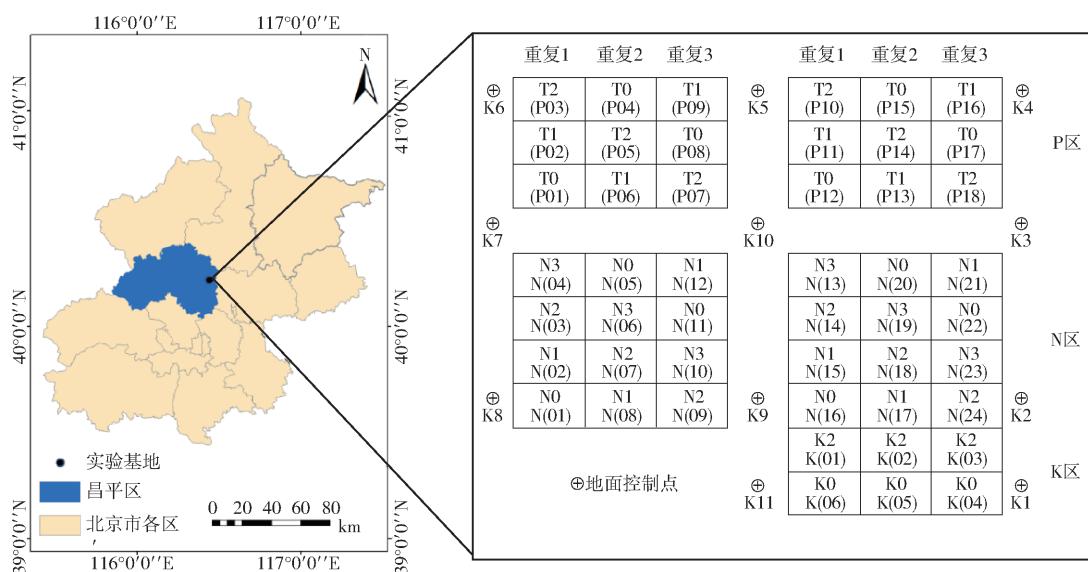


图 1 马铃薯田间位置及实验设计

Fig. 1 Potato field location and experimental design

表 1 无人机飞行参数

Tab. 1 UAV flight parameters

参数	数值/形式
无人机质量/g	1 391
最大飞行速度/(km·h ⁻¹)	50
最大起飞海拔高度/m	6 000
飞行时间/min	30
相机有效像素数	2 000 万
波段	红(R)、绿(G)、蓝(B)
航向重叠度/%	85
旁向重叠度/%	85
飞行高度/m	20

主要步骤包括对齐图像、建立密集点云、生成格网、生成纹理、建立正射、导出数字正射影像。

1.3 地面数据获取

在无人机数据采集结束后进行地面数据采集。马铃薯 PKC 测量方法为田间采样和实验室化学分析相结合。分别于马铃薯块茎形成期、块茎增长期和淀粉积累期在每个实验小区选取 3 株具有代表性

的植株带回实验室进行茎叶分离,用清水冲洗干净后在干燥箱内 105℃ 杀青 30 min,然后将温度调至 80℃ 干燥 48 h 以上,质量恒定后进行称量,得到各器官的干质量。在实验室利用电感耦合等离子体发射光谱仪(iCAP6300 型)测量各器官钾含量。最后计算 PKC,计算公式为

$$PKC = \frac{C_{LK}M_{LD} + C_{SK}M_{SD}}{M_{LD} + M_{SD}} \times 100\% \quad (1)$$

式中 C_{LK} ——叶片钾含量, %

C_{SK} ——地上茎钾含量, %

M_{LD} ——叶片干质量, g

M_{SD} ——地上茎干质量, g

1.4 光谱指数选取

从无人机 RGB 影像中提取每个小区的冠层光谱特征,然后根据现有的研究进展选取 24 个能够描述作物氮素和钾素营养状况的光谱植被指数对马铃薯块茎形成期、块茎增长期、淀粉积累期的 PKC 进行估算。植被指数如表 2 所示。

表 2 植被指数

Tab. 2 Vegetation indices

植被指数	表达式	文献序号	植被指数	表达式	文献序号
R			MGRVI	$(g^2 - r^2) / (g^2 + r^2)$	[12]
G			RGBVI	$(g^2 - br) / (g^2 + br)$	[12]
B			NDI	$(r - g) / (r + g + 0.01)$	[12]
r	$R / (R + G + B)$		GLA	$(2g - r + b) / (2g + r + b)$	[12]
g	$G / (R + G + B)$		CIVE	$0.441r - 0.881g - 0.3856b + 18.78745$	[12]
b	$B / (R + G + B)$		$(g - b) / (r - g)$	$(g - b) / (r - g)$	[12]
$g + b$	$g + b$		EXG	$2g - b - r$	[19]
$g - b$	$g - b$		EXR	$1.4r - g$	[19]
$r - b$	$r - b$		EXGR	$EXG - EXR$	[19]
$r + b$	$R + b$		IKAW	$(r - b) / (r + b)$	[19]
r/g	r/g		GRVI	$(g - r) / (g + r)$	[19]
$(r - g - b) / (r + g)$	$(r - g - b) / (r + g)$	[12]	VARI	$(g - r) / (g + r - b)$	[19]

注: R、G、B 分别表示红、绿、蓝波段的中心波长。

1.5 纹理特征选取

遥感影像的纹理特征可以用来描述图像中的空间分布和灰度分布。GLCM 是用来描述图像中像素灰度值之间关系的一种统计方法。GLCM 纹理特征包括对比度 (Contrast, con)、相关性 (Correlation, cor)、差异性 (Dissimilarity, dis)、熵 (Entropy, ent)、同质性 (Homogenetity, hom)、二阶矩 (Second moment, sm)、方差 (Variance, var) 和均值 (mean)。有研究表明提取纹理时移动窗口大小和方向对结果影响较小, 可以忽略^[23-24]。本研究基于 3 个生育期的 RGB 影像选择 3×3 的窗口, 提取每个波段 45° 方向的 8 个纹理特征, 共 24 个。为了提高纹理指数与马铃薯 PKC 之间的相关性, 本文在单个纹理特征的基础上按照归一化植被指数 (NDVI)、差值植被指数 (DVI) 和比值植被指数 (RVI) 方法构建了 3 个纹理指数 (TIS)——NDTI、DTI 和 RTI。选出最佳的组合方式用来估算马铃薯 PKC, 计算公式为

$$NDTI = \frac{T_1 - T_2}{T_1 + T_2} \quad (2)$$

$$DTI = T_1 - T_2 \quad (3)$$

$$RTI = \frac{T_1}{T_2} \quad (4)$$

式中 T_1, T_2 ——3 个波段中随机纹理特征值

1.6 数据分析方法

将重复 1 和重复 3 的 32 组数据作为训练集建立马铃薯 PKC 的估算模型, 将重复 2 的 16 组数据作为验证集, 验证模型精度。采用的数据分析方法为 MLR、偏最小二乘 (Partial least squares regression, PLSR) 和 ANN。MLR 是一种基本的回归分析方法, 它建立了变量和目标之间的线性关系, 并且假设误

差项是独立同分布的。PLSR 是一种经典的线性回归方法, 它可以解决多重共线性问题, 将原始变量转换为一组新的特征, 并且确保每个成分都与目标相关联, 通过保留这些成分的不同数量, 可以进行多级回归分析, 从而实现预测。ANN 是一种基于神经元结构的非线性建模方法, 通过学习数据中的复杂模式进行建模, 并且可以根据数据的结构和分布来自适应地调整模型参数。

1.7 模型评价指标

为评价模型预测结果的准确性, 采用决定系数 (Coefficient of determination, R^2)、均方根误差 (Root mean square error, RMSE) 和标准均方根误差 (Normalized root mean square error, NRMSE) 作为模型精度评价指标。

2 结果与分析

2.1 相关性分析

采用 Pearson 相关性分析了不同模型参数与马铃薯 PKC 之间的相关性。表 3 为所有模型参数与 3 个生育期马铃薯 PKC 的相关系数。块茎形成期除 IKAW 和 $(g-b)/(r-g)$ 与马铃薯 PKC 表现不显著相关外, 其余植被指数均与马铃薯 PKC 表现显著性相关。其中 G、b 和 r-b 表现为 0.05 水平显著性相关, R、B、r、g、g+b、g-b、r+b、r/g、EXG、EXR、EXGR、GRVI、VARI、 $(r-g-b)/(r+g)$ 、MGRVI、RGBVI、NDI、GLA 和 CIVE 共 19 个植被指数均表现为 0.01 水平显著性相关。相关系数绝对值最大的植被指数是 $(r-g-b)/(r+g)$, 为 0.85。块茎增长期 G 和 $(g-b)/(r-g)$ 与马铃薯 PKC 不显著相关, R、B、r、g、b、g+b、g-b、r-b、r+b、r/g、EXG、EXR、EXGR、IKAW、GRVI、VARI、 $(r-g-b)/(r+g)$ 、

表 3 马铃薯 3 个生育期植被指数与 PKC 的相关系数

Tab. 3 Correlation coefficient between vegetation index and PKC in three growth periods of potato

植被指数	PKC			植被指数	PKC		
	块茎形成期	块茎增长期	淀粉积累期		块茎形成期	块茎增长期	淀粉积累期
R	-0.54 **	-0.57 **	-0.76 **	EXR	-0.72 **	-0.82 **	-0.65 **
G	-0.31 *	-0.19	-0.41 **	EXGR	0.67 **	0.79 **	0.63 **
B	-0.42 **	-0.60 **	-0.64 **	IKAW	0.02	0.59 **	0.34 *
r	-0.84 **	-0.77 **	-0.68 **	GRVI	0.70 **	0.80 **	0.64 **
g	0.59 **	0.75 **	0.59 **	VARI	0.71 **	0.80 **	0.64 **
b	-0.30 *	-0.65 **	-0.46 **	$(r-g-b)/(r+g)$	-0.85 **	-0.54 **	-0.65 **
g+b	0.84 **	0.77 **	0.68 **	MGRVI	0.70 **	0.80 **	0.64 **
g-b	0.48 **	0.71 **	0.54 **	RGBVI	0.53 **	0.72 **	0.56 **
r-b	-0.33 *	0.48 **	0.12	NDI	-0.70 **	-0.80 **	-0.64 **
r+b	-0.59 **	-0.75 **	-0.59 **	GLA	0.78 **	0.85 **	0.67 **
r/g	-0.69 **	-0.80 **	-0.64 **	CIVE	-0.73 **	-0.83 **	-0.65 **
EXG	0.59 **	0.75 **	0.59 **	$(g-b)/(r-g)$	-0.17	-0.24	-0.34 *

注: * 表示 0.05 水平显著性相关, ** 表示 0.01 水平显著性相关。下同。

MGRVI、RGBVI、NDI、GLA 和 CIVE 共 22 个植被指数与马铃薯 PKC 表现为 0.01 水平显著性相关。相关系数绝对值最大的植被指数是 GLA, 为 0.85。淀粉积累期 r-b 与马铃薯 PKC 为不显著相关, IKAW 和 $(g-b)/(r-g)$ 表现为 0.05 水平显著性相关, R、G、B、r、g、b、g+b、g-b、r+b、r/g、EXG、EXR、EXGR、GRVI、VARI、 $(r-g-b)/(r+g)$ 、MGRVI、RGBVI、NDI、GLA 和 CIVE 共 21 个植被指数与马铃薯 PKC 表现为 0.01 水平显著性相关。相关系数绝对值最大的植被指数是 R, 为 0.76。

如表 4 所示, 单一纹理特征在块茎形成期 R-ent 和 B-hom 与马铃薯 PKC 不显著相关, G-mean 和 G-ent 表现为 0.05 水平显著性相关, R-mean、R-var、R-hom、R-con、R-dis、R-sec、R-cor、G-var、G-hom、G-con、G-dis、G-sec、G-cor、B-mean、B-var、B-con、B-dis、B-ent、B-sec 和 B-cor 共 20 个纹理特征与马铃薯 PKC 呈 0.01 水平显著性相关。相关系数绝对值最大的是 G-con, 为 0.79。块茎增长期 G-mean 表现为不显著相关外,

其余纹理指数均表现为显著性相关。其中 R-cor 和 G-cor 表现为 0.05 水平显著性相关, R-mean、R-var、R-hom、R-con、R-dis、R-ent、R-sec、G-var、G-hom、G-con、G-dis、G-ent、G-sec、B-mean、B-var、B-hom、B-con、B-dis、B-ent、B-sec 和 B-cor 共 21 个单一纹理特征与马铃薯 PKC 呈 0.01 水平显著性相关。相关系数绝对值最大的是 R-var 和 R-dis, 为 0.82。淀粉积累期 G-cor、B-var、B-hom、B-con、B-dis 和 R-cor 与马铃薯 PKC 不显著相关。R-mean、R-var、R-hom、R-con、R-dis、R-ent、R-sec、G-mean、G-var、G-hom、G-con、G-dis、G-ent、G-sec、B-mean、B-ent、B-sec 和 B-cor 共 18 个单一纹理特征表现为 0.01 水平显著性相关。相关系数绝对值最大的是 R-mean, 为 0.76。构建的 3 个 TIS 在 3 个生育期均表现为 0.01 水平显著性相关, 相关系数绝对值均大于表现最优的单一纹理特征相关系数绝对值, 且 3 个生育期 NDTI、DTI 和 RTI 相关系数绝对值相差不大, 相关系数绝对值最大为 0.84、0.83 和 0.78。

表 4 马铃薯 3 个生育期纹理特征与 PKC 的相关系数

Tab. 4 Correlation coefficient of texture characteristics and PKC in three growth stages of potato

纹理特征	PKC			纹理特征	PKC		
	块茎形成期	块茎增长期	淀粉积累期		块茎形成期	块茎增长期	淀粉积累期
R-mean	-0.54 **	-0.57 **	-0.76 **	G-sec	0.45 **	-0.73 **	-0.48 **
R-var	0.78 **	0.82 **	0.40 **	G-cor	-0.75 **	-0.29 *	0.01
R-hom	-0.41 **	-0.78 **	-0.47 **	B-mean	-0.42 **	-0.60 **	-0.64 **
R-con	0.78 **	0.81 **	0.39 **	B-var	0.66 **	0.79 **	-0.17
R-dis	0.75 **	0.82 **	0.43 **	B-hom	-0.11	-0.71 **	0.11
R-ent	-0.24	0.74 **	0.49 **	B-con	0.71 **	0.79 **	-0.15
R-sec	0.41 **	-0.73 **	-0.49 **	B-dis	0.68 **	0.78 **	-0.03
R-cor	-0.75 **	-0.29 *	0.14	B-ent	-0.39 **	0.64 **	-0.35 **
G-mean	-0.31 *	-0.19	-0.41 **	B-sec	0.48 **	-0.60 **	0.42 **
G-var	0.79 **	0.81 **	0.39 **	B-cor	-0.72 **	-0.42 **	-0.44 **
G-hom	-0.38 **	-0.78 **	-0.47 **	NDTI	-0.82 **	-0.83 **	-0.77 **
G-con	0.79 **	0.80 **	0.38 **	RTI	0.84 **	0.83 **	-0.78 **
G-dis	0.75 **	0.81 **	0.43 **	DTI	-0.82 **	0.82 **	-0.77 **
G-ent	-0.29 *	0.74 **	0.49 **				

注: R-mean 表示 R 的 mean 纹理特征, 其他类推。

2.2 马铃薯 PKC 估算与验证

分别以 3 个生育期相关系数绝对值最大的 3 个植被指数和构建的 3 个最优的 TIS 为输入变量, 结合 MLR、PLSR 和 ANN 构建马铃薯 PKC 的估算模型。表 5、6 分别为 3 个生育期 MLR、PLSR 和 ANN 3 种方法以植被指数(VIS)和植被指数结合构建的 TIS 为输入变量建模和验证的结果。3 个生育期利用同种建模方法植被指数结合 TIS 作为输入变量估算 PKC 的效果优于仅将植被指数作为输入变量的

估算效果。3 种建模方法均表现为块茎形成期和块茎增长期的估算效果优于淀粉积累期; 同种建模方法从块茎形成期到淀粉积累期模型验证精度逐渐变差。不同的估算模型在 3 个生育期植被指数结合 TIS 的建模和验证效果如图 2 所示。3 个生育期 MLR 和 PLSR 的建模和验证结果均优于 ANN。

不同建模方法中均是块茎形成期和块茎增长期估算效果较好, 各样本点分布在 1:1 线附近。块茎形成期 MLR、PLSR 和 ANN 建模 R^2 分别为 0.82、

表 5 3 个生育期 3 种方法马铃薯 PKC 估算结果对比

Tab. 5 Comparison of potato PKC estimation results of three methods in three growth period

生育期	变量	MLR			PLSR			ANN		
		R ²	RMSE/%	NRMSE/%	R ²	RMSE/%	NRMSE/%	R ²	RMSE/%	NRMSE/%
块茎形成期	VIS	0.74	0.38	12.44	0.67	0.42	12.20	0.61	0.53	17.35
	VIS + TIS	0.82	0.32	10.41	0.80	0.33	9.59	0.75	0.40	13.02
块茎生长期	VIS	0.79	0.36	11.77	0.76	0.39	12.69	0.69	0.48	15.72
	VIS + TIS	0.84	0.31	10.07	0.80	0.36	11.60	0.71	0.48	15.63
淀粉积累期	VIS	0.68	0.33	13.77	0.68	0.33	13.77	0.63	0.36	15.34
	VIS + TIS	0.70	0.31	13.16	0.70	0.32	13.36	0.66	0.34	14.15

表 6 3 个生育期 3 种方法马铃薯 PKC 验证结果对比

Tab. 6 Comparison of potato PKC verification results of three methods in three growth periods

生育期	变量	MLR			PLSR			ANN		
		R ²	RMSE/%	NRMSE/%	R ²	RMSE/%	NRMSE/%	R ²	RMSE/%	NRMSE/%
块茎形成期	VIS	0.86	0.28	9.23	0.84	0.30	7.97	0.68	0.55	18.15
	VIS + TIS	0.86	0.31	10.13	0.88	0.29	7.79	0.75	0.46	15.26
块茎生长期	VIS	0.64	0.47	15.15	0.68	0.42	13.72	0.54	0.58	18.76
	VIS + TIS	0.68	0.43	13.97	0.72	0.41	13.35	0.54	0.54	17.75
淀粉积累期	VIS	0.56	0.47	20.02	0.56	0.48	20.02	0.55	0.48	20.29
	VIS + TIS	0.60	0.45	19.02	0.58	0.46	19.33	0.57	0.47	19.73

0.80 和 0.75, RMSE 分别为 0.32%、0.33% 和 0.40%, NRMSE 分别为 10.41%、9.59% 和 13.02%。验证 R^2 分别为 0.86、0.88 和 0.75, RMSE 分别为 0.31%、0.29% 和 0.46%, NRMSE 分别为 10.13%、7.79% 和 15.26%。块茎生长期 MLR 建模精度最高 R^2 为 0.84, RMSE 为 0.31%, NRMSE 为 10.07%。PLSR 建模 R^2 、RMSE 和 NRMSE 分别为 0.80、0.36% 和 11.60%。ANN 建模 R^2 、RMSE 和 NRMSE 分别为 0.71、0.48% 和 15.63%。验证集上 PLSR 表现最优, R^2 为 0.72, RMSE 为 0.41%, NRMSE 为 13.35%。MLR 建模 R^2 、RMSE 和 NRMSE 分别为 0.68、0.43% 和 13.97%。ANN 建模 R^2 、RMSE 和 NRMSE 分别为 0.54、0.54% 和 17.75%。淀粉积累期 3 个模型中 MLR 估算精度最高, 建模 R^2 为 0.70, RMSE 为 0.31%、NRMSE 为 13.16%。PLSR 建模 R^2 、RMSE 和 NRMSE 分别为 0.70、0.32% 和 13.36%。ANN 建模 R^2 、RMSE 和 NRMSE 分别为 0.66、0.34% 和 14.15%。MLR 验证 R^2 、RMSE 和 NRMSE 分别为 0.60、0.45% 和 19.02%。PLSR 验证 R^2 、RMSE 和 NRMSE 分别为 0.58、0.46% 和 19.33%。ANN 验证 R^2 、RMSE 和 NRMSE 分别为 0.57、0.47% 和 19.73%。

3 讨论

3.1 植被指数估算马铃薯 PKC

本研究基于无人机遥感平台获取了马铃薯块茎形成期、块茎生长期和淀粉积累期的 RGB 影像, 基

于冠层光谱特征构建植被指数并与马铃薯 3 个生育期的 PKC 进行相关性分析, 选取相关系数绝对值最高的 3 个植被指数建模估算马铃薯 PKC, 块茎形成期和块茎生长期马铃薯 PKC 估算效果较好, 其原因是马铃薯前期以茎叶生长为主, 到块茎形成期马铃薯地上茎叶已经基本发育完整, 地上茎叶生长开始缓慢, 块茎生长期马铃薯已由单纯的植株营养生长过渡到植株营养生长、生殖生长和物质积累同时进行的时期, 此阶段是马铃薯整个生长发育的鼎盛时期, 地上茎叶生长茂盛^[25]。这两个生育期提取的光谱特征受土壤影响较小, 构建的植被指数能够较好地反映马铃薯 PKC 变化情况。经过对比发现 3 个生育期通过 3 种方法建模时淀粉积累期精度稍差。这是因为在淀粉积累期马铃薯地上茎叶停止生长, 地下块茎基本停止生长, 此阶段以淀粉积累为主, 淀粉和蛋白质等营养物质不断增加。地上部营养物质开始向地下转移, 地上茎叶开始变黄枯萎, 地面开始裸露, 导致提取的光谱信息受到土壤的影响, 构建的植被指数与马铃薯 PKC 相关性降低^[26]。

3.2 植被指数结合 TIS 估算马铃薯 PKC

纹理信息可以增加无人机图像的数据维数, 经对比发现由单个纹理特征组合得到的 TIS 与马铃薯 PKC 之间的相关系数绝对值均大于单个纹理特征。这是因为 TIS 可以通过平滑冠层结构降低土壤背景、太阳高度角和传感器视角的影响^[27]。本研究基于 3 个生育期的植被指数结合 TIS 构建马铃薯 PKC 的估算模型。发现植被指数结合 TIS 构建的模型精

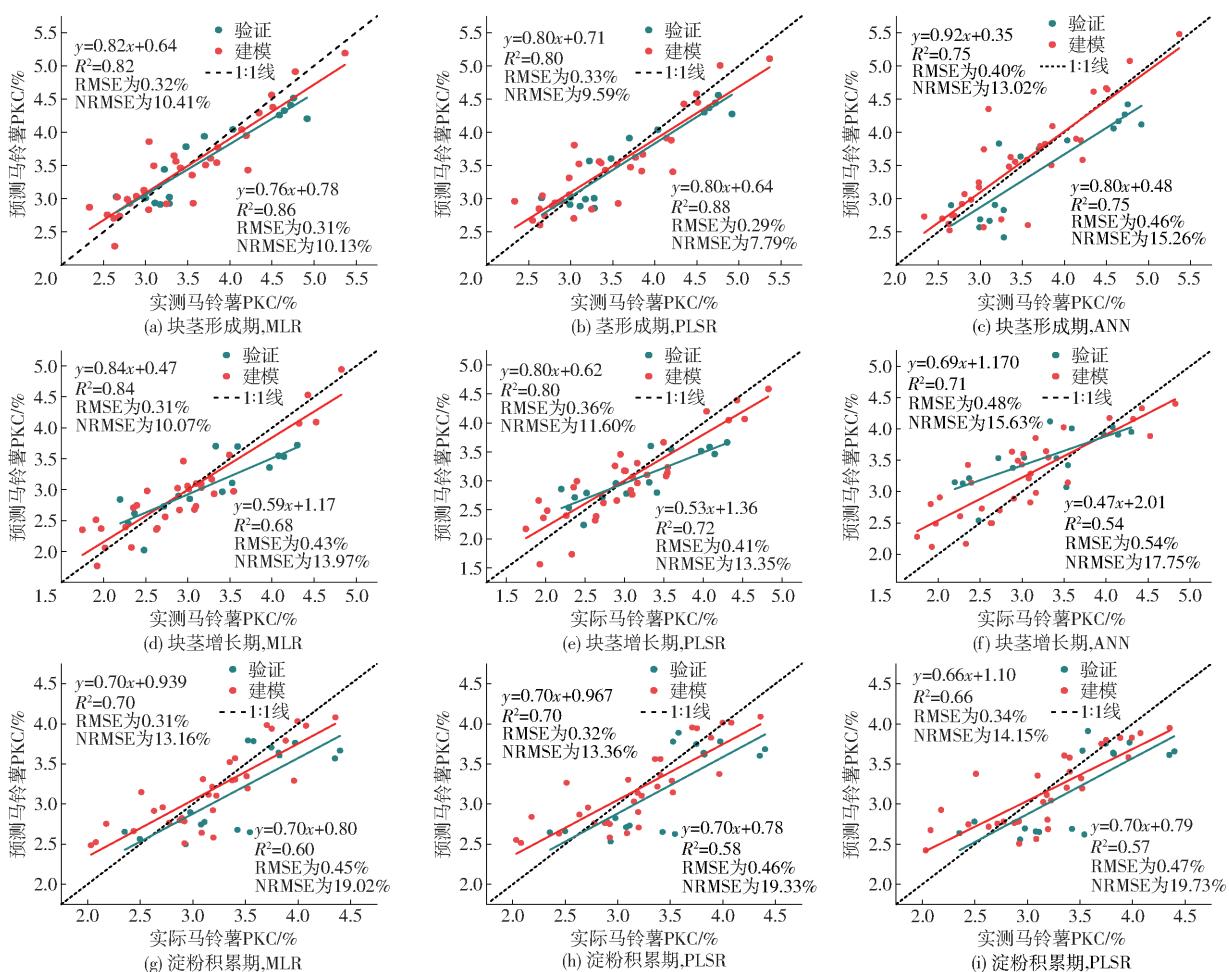


图 2 不同估算模型下 3 个生育期植被指数结合 TIS 建模和验证效果

Fig. 2 Modeling and verification effects of vegetation indices of three growth periods combined with TIS based on different estimation models

度高于仅用植被指数构建的模型精度。这与马铃薯自身生长发育有关,块茎形成期和块茎增长期马铃薯茎叶生长旺盛,植被覆盖度较大。在高覆盖度下纹理特征对作物物理特性敏感,可以很好地反映冠层结构变化。随着生育期的变化,由于营养的消耗和追肥的影响叶片颜色会发生变化。块茎形成期和块茎增长期营养物质主要集中在地上的茎和叶中,马铃薯冠层颜色由浅变深。淀粉积累期地上茎叶中营养物质不断向地下转移,冠层颜色由绿逐渐变黄。纹理特征也可以反映这些颜色变化^[28-29]。光谱特征和纹理特征对马铃薯 PKC 的表现不同,相较于仅用植被指数建立的估算模型,植被指数结合 TIS 可以更全面地反映遥感信息与作物参数之间的关系。这与 ZHENG 等^[30]研究结论一致,表明植被指数结合 TIS 可以提高估算作物物理化参数的精度。

本研究构建的 3 种马铃薯 PKC 估算模型中 MLR 和 PLSR 估算精度和模型稳定性高于 ANN。这是因为 MLR 可以更加有效地利用多个变量信息,提高对目标的解释能力。PLSR 可以在变量和目标之间提取主成分,减少特征和目标之间的冗余信息,

提高模型的准确性,在样本量较小的情况下,PLSR 仍然能够得到可靠的结果。ANN 往往在处理大规模和非线性问题时表现优异^[31]。本研究所用的数据集较小且变量之间存在一定的共线性,ANN 在训练中反复学习细节可能给出错误的权重,导致估算能力较差。此外,本研究基于国家精准农业研究示范基地一年的观测数据进行建模和验证,构建的模型是否适用于不同地点及不同年限有待进一步研究。

4 结论

(1) 基于单一纹理特征构建的 TIS 与马铃薯 PKC 在 3 个生育期均达到 0.01 水平显著性相关,块茎形成期 NDTI、RTI 和 DTI 与马铃薯 PKC 相关系数绝对值分别为 0.82、0.84 和 0.82,块茎增长期 NDTI、RTI 和 DTI 与马铃薯 PKC 相关系数绝对值分别为 0.83、0.83 和 0.82,淀粉积累期 NDTI、RTI 和 DTI 与马铃薯 PKC 相关系数绝对值分别为 0.77、0.78 和 0.77。相关系数绝对值均高于最高的单一纹理特征的相关系数绝对值。

(2) MLR 和 PLSR 的建模效果较好, 块茎形成期 R^2 分别为 0.82 和 0.80, RMSE 分别为 0.32% 和 0.33%, NRMSE 分别为 10.41% 和 9.59%。块茎增长期 R^2 分别为 0.84 和 0.80, RMSE 分别为 0.31% 和 0.36%, NRMSE 分别为 10.07% 和 11.60%。淀

粉积累期 R^2 分别为 0.70 和 0.70, RMSE 分别为 0.31% 和 0.32%, NRMSE 分别为 13.16% 和 13.36%。相较于仅用植被指数建模, 3 个生育期加入 TIS 构建的马铃薯 PKC 估算模型精度均有所提高。

参 考 文 献

- [1] 罗其友, 高明杰, 张烁, 等. 中国马铃薯产业国际比较分析[J]. 中国农业资源与区划, 2021, 42(7): 1–8.
LUO Qiyou, GAO Mingjie, ZHANG Shuo, et al. Comparative analysis on potato industry between China and other countries[J]. China Agricultural Resources and Regional Planning, 2021, 42(7): 1–8. (in Chinese)
- [2] 卢茗. 钾肥施用量对马铃薯产量和品质的影响[J]. 中国农业文摘——农业工程, 2022, 34(5): 44–47.
- [3] 张茹艳, 张卫娜, 康益晨, 等. 钾素对马铃薯组培苗生长及生理生化特性的影响[J]. 甘肃农业大学学报, 2021, 56(2): 61–67.
ZHANG Ruyan, ZHANG Weina, KANG Yichen, et al. Effects of potassium on growth properties, physicochemical characteristics of potato tissue cultured seedlings[J]. Journal of Gansu Agricultural University, 2021, 56(2): 61–67. (in Chinese)
- [4] 刘杨, 孙乾, 黄珏, 等. 无人机多光谱影像的马铃薯地上生物量估算[J]. 光谱学与光谱分析, 2021, 41(8): 2549–2555.
LIU Yang, SUN Qian, HUANG Jue, et al. Estimation of potato above ground biomass based on UAV multispectral images[J]. Spectroscopy and Spectral Analysis, 2021, 41(8): 2549–2555. (in Chinese)
- [5] 鲁向晖, 杨宝城, 张海娜, 等. 基于无人机多光谱遥感的矮林芳樟叶片精油产量反演[J]. 农业机械学报, 2023, 54(4): 191–197, 213.
LU Xianghui, YANG Baocheng, ZHANG Haina, et al. Inversion of leaf essential oil yield of *Cinnamomum camphora* based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 191–197, 213. (in Chinese)
- [6] 蒋小敏, 冯海宽, 常红, 等. 基于数码图像的小麦条锈病病害程度分级方法[J]. 江苏农业科学, 2021, 49(23): 109–115.
JIANG Xiaomin, FENG Haikuan, CHANG Hong, et al. Classification method of wheat stripe rust disease degree based on digital image[J]. Jiangsu Agricultural Sciences, 2021, 49(23): 109–115. (in Chinese)
- [7] JIN X, KUMAR L, LI Z, et al. A review of data assimilation of remote sensing and crop models[J]. European Journal of Agronomy, 2018, 92: 141–152.
- [8] YUAN H, YANG G, LI C, et al. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: analysis of RF, ANN, and SVM regression models[J]. Remote Sensing, 2017, 9(4): 309.
- [9] LU J, LI W, YU M, et al. Estimation of rice plant potassium accumulation based on non-negative matrix factorization using hyperspectral reflectance[J]. Precision Agriculture, 2021, 22: 51–74.
- [10] THOMSON E R, MALHI Y, BARTHOLOMEUS H, et al. Mapping the leaf economic spectrum across West African tropical forests using UAV-acquired hyperspectral imagery[J]. Remote Sensing, 2018, 10(10): 1532.
- [11] SEVERTSON D, CALLOW N, FLOWER K, et al. Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola[J]. Precision Agriculture, 2016, 17: 659–677.
- [12] 樊意广, 冯海宽, 刘杨, 等. 基于冠层光谱特征和株高的马铃薯植株氮含量估算[J]. 农业机械学报, 2022, 53(6): 202–208, 294.
FAN Yiguang, FENG Haikuan, LIU Yang, et al. Estimation of potato plant nitrogen content based on canopy spectral characteristics and plant height[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 202–208, 294. (in Chinese)
- [13] 刘杨, 冯海宽, 黄珏, 等. 基于无人机数码影像的马铃薯生物量估算[J]. 农业工程学报, 2020, 36(23): 181–192.
LIU Yang, FENG Haikuan, HUANG Jue, et al. Estimation of potato biomass based on UAV digital images[J]. Transactions of the CSAE, 2020, 36(23): 181–192. (in Chinese)
- [14] 陶惠林, 徐良骥, 冯海宽, 等. 基于无人机数码影像的冬小麦株高和生物量估算[J]. 农业工程学报, 2019, 35(19): 107–116.
TAO Huilin, XU Liangji, FENG Haikuan, et al. Estimation of plant height and biomass of winter wheat based on UAV digital images[J]. Transactions of the CSAE, 2019, 35(19): 107–116. (in Chinese)
- [15] MAO P, QIN L, HAO M, et al. An improved approach to estimate above-ground volume and biomass of desert shrub communities based on UAV RGB images[J]. Ecological Indicators, 2021, 125: 107494.
- [16] YUE J, ZHOU C, GUO W, et al. Estimation of winter-wheat above-ground biomass using the wavelet analysis of unmanned aerial vehicle-based digital images and hyperspectral crop canopy images[J]. International Journal of Remote Sensing, 2021, 42(5): 1602–1622.
- [17] WU L, GONG Y, BAI X, et al. Nondestructive determination of leaf nitrogen content in corn by hyperspectral imaging using spectral and texture fusion[J]. Applied Sciences, 2023, 13(3): 1910.
- [18] GAO C, JI X, HE Q, et al. Monitoring of wheat fusarium head blight on spectral and textural analysis of UAV multispectral imagery[J]. Agriculture, 2023, 13(2): 293.

- [34] 李书琴,陈聪,朱彤,等. 基于轻量级残差网络的植物叶片病害识别[J]. 农业机械学报, 2022, 53(3): 243–250.
Li Shuqin, CHEN Cong, ZHU Tong, et al. Plant leaf disease identification based on lightweight residual network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 243–250. (in Chinese)
- [35] HU J, SHEN L, SUN G, et al. Squeeze-and-Excitation networks[C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132–7141.
- [36] HUGHES D, SALAATHÉ M. An open access repository of images on plant health to enable the development of mobile disease diagnostics[J]. arXiv preprint arXiv:1511.08060, 2015.
- [37] PULGAR F J, RIVERA A J, CHARTE F, et al. On the impact of imbalanced data in convolutional neural networks performance[C]//12th International Conference on Hybrid Artificial Intelligent Systems (HAIS), 2017: 220–232.
- [38] BUDA M, MAKI A, MAZUROWSKI M A. A systematic study of the class imbalance problem in convolutional neural networks [J]. Neural Networks, 2018, 106: 249–259.
- [39] WANG S J, LIU W, WU J, et al. Training deep neural networks on imbalanced data sets[C]//International Joint Conference on Neural Networks (IJCNN), 2016: 4368–4374.
- [40] WOO S H, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//15th European Conference on Computer Vision (ECCV), 2018: 3–19.
- [41] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: visual explanations from deep networks via gradient-based localization[J]. International Journal of Computer Vision, 2020, 128(2): 336–359.
- [42] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C]//IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314–1324.
- [43] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012–10022.

(上接第 203 页)

- [19] LU J, EITEL J U, ENGELS M, et al. Improving unmanned aerial vehicle (UAV) remote sensing of rice plant potassium accumulation by fusing spectral and textural information [J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 104: 102592.
- [20] ZHENG H, CHENG T, ZHOU M, et al. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery[J]. Precision Agriculture, 2019, 20: 611–629.
- [21] MA Y, MA L, ZHANG Q, et al. Cotton yield estimation based on vegetation indices and texture features derived from RGB image[J]. Frontiers in Plant Science, 2022, 13: 1983.
- [22] LIU Y, FENG H, YUE J, et al. Remote-sensing estimation of potato above-ground biomass based on spectral and spatial features extracted from high-definition digital camera images[J]. Computers and Electronics in Agriculture, 2022, 198: 107089.
- [23] FU Y, YANG G, LI Z, et al. Winter wheat nitrogen status estimation using UAV-based RGB imagery and Gaussian processes regression[J]. Remote Sensing, 2020, 12(22): 3778.
- [24] 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.
- [25] LIU Y, FENG H, YUE J, et al. Estimation of potato above-ground biomass based on unmanned aerial vehicle red-green-blue images with different texture features and crop height[J]. Frontiers in Plant Science, 2022, 13: 938216.
- [26] FAN Y, FENG H, JIN X, et al. Estimation of the nitrogen content of potato plants based on morphological parameters and visible light vegetation indices[J]. Frontiers in Plant Science, 2022, 13: 1012070.
- [27] HE J, ZHANG N, SU X, et al. Estimating leaf area index with a new vegetation index considering the influence of rice panicles[J]. Remote Sensing, 2019, 11(15): 1809.
- [28] DUBE T, MUTANGA O. Investigating the robustness of the new Landsat-8 operational land imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 108: 12–32.
- [29] YANG W H, PENG S, HUANG J, et al. Using leaf color charts to estimate leaf nitrogen status of rice[J]. Agronomy Journal, 2003, 95(1): 212–217.
- [30] ZHENG H, MA J, ZHOU M, et al. Enhancing the nitrogen signals of rice canopies across critical growth stages through the integration of textural and spectral information from unmanned aerial vehicle (UAV) multispectral imagery[J]. Remote Sensing, 2020, 12(6): 957.
- [31] 刘杨, 黄珏, 孙乾, 等. 利用无人机数码影像估算马铃薯地上生物量[J]. 遥感学报, 2021, 25(9): 2004–2014.
LIU Yang, HUANG Jue, SUN Qian, et al. Estimation of plant height and above ground biomass of potato based on UAV digital image[J]. National Remote Sensing Bulletin, 2021, 25(9): 2004–2014. (in Chinese)