

基于无人机多光谱影像的夏玉米 SPAD 估算模型研究

冯浩^{1,2} 杨祯婷^{1,3} 陈浩⁴ 吴莉鸿^{1,3} 李成^{1,3} 王乃江^{1,3}

- (1. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;
- 2. 中国科学院水利部水土保持研究所, 陕西杨凌 712100;
- 3. 西北农林科技大学中国旱区节水农业研究院, 陕西杨凌 712100;
- 4. 中国电建集团西北勘测设计研究院有限公司, 西安 710065)

摘要: 快速获取作物叶片叶绿素含量对及时诊断作物健康状况、指导田间管理具有重要意义。本研究以关中地区 2020 年夏玉米为研究对象, 获取试验区无人机多光谱影像, 提取植被指数, 分析所选植被指数与 SPAD 的相关性, 筛选得到模型的输入变量, 利用偏最小二乘法 (PLS)、随机森林回归 (RF) 和分层线性模型 (HLM) 分别构建拔节期、抽雄期、灌浆期以及全生育期的 SPAD 估算模型, 最终选出最优估算模型, 以为快速获取夏玉米 SPAD 提供参考。研究发现: 除 NRI 之外, NDVI、OSAVI、GNDVI、RVI、MCARI、MSR、CI_{re} 与 SPAD 均显著相关, 其中, OSAVI、NDVI 与 SPAD 呈现出较强且稳定的相关性; 各个生育期的最优模型均是 RF 模型, 在拔节期、抽雄期、灌浆期和全生育期, 验证集 R^2 分别为 0.81、0.81、0.73、0.61, RMSE 分别为 1.24、2.32、3.13、3.20; 对于 SPAD 估算模型, 将降雨量、最高气温这两个气象因子与植被指数耦合的 HLM 模型可以一定程度提升线性模型的估算精度, 但其精度低于 RF 模型。因此, 基于无人机多光谱影像的 RF 模型可以实现夏玉米 SPAD 的快速准确估算。

关键词: 无人机; 多光谱; 夏玉米; SPAD; 分层线性模型

中图分类号: S127; S513 文献标识码: A 文章编号: 1000-1298(2022)10-0211-09 OSID: 

Estimation of Summer Maize SPAD Based on UAV Multispectral Images

FENG Hao^{1,2} YANG Zhengting^{1,3} CHEN Hao⁴ WU Lihong^{1,3} LI Cheng^{1,3} WANG Naijiang^{1,3}

- (1. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China
- 2. Institute of Soil and Water Conservation, Chinese Academy of Sciences and Ministry of Water Resources, Yangling, Shaanxi 712100, China
- 3. Institute of Water-saving Agriculture in Arid Areas of China, Northwest A&F University, Yangling, Shaanxi 712100, China
- 4. Northwest Engineering Corporation Limited of Power China, Xi'an 710065, China)

Abstract: Obtaining chlorophyll content of crops rapidly is of great significance for timely diagnosing the health status of crops and guiding field management. In recent years, the development of unmanned aerial vehicle (UAV) has made it possible to quickly and accurately obtain information at the farm scale. The purpose was to estimate SPAD of summer maize based on UAV multispectral images, especially focusing on whether the hierarchical linear model with meteorological data had high accuracy. SPAD in the jointing stage, the tasseling stage and the filling stage were measured by SPAD-502Plus chlorophyll meter, and the multispectral images were captured by RedEdge mounted on DJI M600 Pro. Firstly, the vegetation indices of 21 experimental plots were extracted by band math and establishing the region of interest. Then, the correlation between the vegetation indices and SPAD was analyzed, and the vegetation indices with high correlation coefficient were selected as the input variables of SPAD estimation model. At last, the SPAD estimation models for the jointing stage, the tasseling stage, the filling stage and the whole growth stage were constructed by using partial least squares (PLS), random forest regression (RF) and hierarchical linear model (HLM), respectively. The results were compared to select the best model, which could provide support for SPAD estimation. It was found that except NRI, other vegetation indices (NDVI, OSAVI, GNDVI, RVI, MCARI, MSR, CI_{re}) were significantly correlated with SPAD,

furthermore, OSAVI and NDVI had strong and stable correlation with SPAD. The best model for each growth period was established by RF. For the jointing stage, the tasseling stage, the filling stage and the whole growth period, the R^2 of the test set was 0.81, 0.81, 0.73 and 0.61, and the RMSE was 1.24, 2.32, 3.13 and 3.20, respectively. The HLM model, which coupled rainfall and maximum temperature with vegetation index, could improve the accuracy of linear model for estimating SPAD, but its accuracy was lower than that of RF. Therefore, the RF model based on UAV multispectral images could realize the estimation of SPAD of summer maize timely and accurately.

Key words: unmanned aerial vehicle; multispectral; summer maize; SPAD; hierarchical linear model

0 引言

近年来,随着精准农业的发展,农业遥感技术应用的广度和深度不断扩展,不仅要求能获得传统的产量、种植面积,还要能够及时获取作物的健康状况,进而指导田间管理^[1-2]。叶绿素是植物进行光合作用的主要色素,是表征植物营养胁迫、光合作用能力的重要因子,是进行作物长势监测的重要指标之一^[3-4]。叶绿素相对含量 (Soil and plant analyzer development, SPAD) 与叶绿素含量密切相关,可以反映植物叶片叶绿素含量,测量 SPAD 是获取叶绿素含量的一种无损、便捷的方法^[5-6]。

目前遥感数据源主要有地物光谱仪、无人机以及卫星。地物光谱仪主要进行点尺度数据的获取,难以进行大范围的观测,同时数据采集会对农田造成一定程度的破坏。卫星遥感数据时间和空间分辨率均较大,所以卫星遥感更适合区域尺度产量、种植面积和作物长势等的监测。相比之下,无人机具有成本低、灵活性高、机动性强、时空分辨率高、操作方便等特点,进行田块尺度作物长势监测有无可比拟的优势^[7]。

在利用遥感数据估算 SPAD 的研究中,主要有 3 种方法:经验模型、物理模型以及经验-物理耦合模型^[8],其中,以有关经验模型的研究居多^[9-14]。乔浪等^[12]从无人机 RGB 图像中提取了 10 种颜色特征和 6 种纹理特征,采用 BP 神经网络建立玉米冠层叶绿素含量检测模型,模型的决定系数为 0.72。牛庆林等^[13]将可见光植被指数与多光谱植被指数结合,利用逐步回归和随机森林回归方法估算 SPAD 值,模型的决定系数均能达到 0.88 以上。

经验模型是建立基于冠层影像得到的光谱指数、植被指数等与实测 SPAD 之间的数学统计关系,参数少,模型简单,应用简便,也能够取得精度较高的建模结果,但缺乏物理意义,不同时间地点建模结果相差大,难以移用。近年来,有研究者尝试将气象数据和植被指数结合,建立分层线性模型进行产量等的估算,取得了一些成果。LI 等^[15]结合高光谱和气象数据,利用分层线性模型建立了小麦产量和品

质的年际可扩展预测模型,结果表明,分层线性模型是一种提高冬小麦产量和籽粒蛋白质含量预测稳定性的方法。ZHU 等^[16]以归一化植被指数和气象数据作为输入参数,建立分层线性模型估算 2016—2019 年吉林省玉米产量,结果显示,分层线性模型优于线性回归和多元线性回归方法。XU 等^[17]将植被指数与欧洲中尺度天气预报中心气象数据使用分层线性模型耦合,构建河北省 4 个小麦产区籽粒蛋白质含量预测模型,研究结果表明,使用 HLM 方法 ($R^2 = 0.524$) 预测的籽粒蛋白质含量比线性模型 ($R^2 = 0.286$) 显示出更高的准确性。

以上研究表明,加入气象数据可以有效提高产量和籽粒蛋白质含量的模型精度,提升经验模型在时空上的通用性。然而,以上研究都是与一元线性或多元线性模型做对比,融合了气象数据的分层线性模型是否比其他模型精度高需要进一步探究。同时,对于能否提升 SPAD 估算模型的精度也是未知的。因此,本研究将基于无人机多光谱影像提取植被指数,以筛选后的植被指数作为模型输入变量,采用偏最小二乘法、随机森林回归和分层线性模型分别构建 2020 年夏玉米拔节期、抽雄期、灌浆期以及全生育期的 SPAD 估算模型,进行模型评价,选出最优估算模型,以期 SPAD 估算提供参考。

1 估算模型构建

1.1 研究区概况

研究区位于陕西省杨凌区西北农林科技大学灌溉试验站 (34°20'N, 108°24'E, 海拔 521 m)。该区域属于暖温带半湿润气候区,多年平均气温为 12.9℃,多年平均降水量为 630 mm,降水集中在 7—10 月。试验采用随机区组设计,根据施氮量不同和是否追肥共设置 7 个处理:CK、N₁₋₁、N₁₋₂、N₂₋₁、N₂₋₂、N₃₋₁、N₃₋₂。施氮量分为 4 个水平,分别为 CK (不施肥)、N1 (105 kg/hm²)、N2 (210 kg/hm²)、N3 (315 kg/hm²);N₁₋₁、N₂₋₁、N₃₋₁为氮肥全部基施,N₁₋₂、N₂₋₂、N₃₋₂为 60% 氮肥基施,剩余 40% 在拔节期追施。每个处理设置 3 个重复,共 21 个小区,每个小区面积为 20 m²。供试玉米品种为秦龙 14,生

育期内不灌溉,施磷肥量 90 kg/hm²。研究区位置及试验设置如图 1 所示。




图 1 研究区概况

Fig. 1 Location of study area and experimental design

1.2 无人机影像获取与预处理

本研究采用大疆 M600 Pro 搭载 RedEdge 多光谱相机作为无人机多光谱影像采集系统,如图 2 所示,多光谱相机的参数如表 1 所示。



图 2 无人机多光谱影像采集系统

Fig. 2 UAV for acquiring multispectral images

分别于 2020 年 7 月 20 日(拔节期)、2020 年 8 月 9 日(抽雄期)、2020 年 8 月 26 日(灌浆期)进行无人机影像采集。采集时,在晴朗无云的天气条件

进行,飞行时间选择 11:00—13:00,设置飞行高度为 30 m,航向重叠度为 80%,旁向重叠度为 80%。无人机在起飞之前,对灰板进行拍照,用于之后的辐射定标,拍照时避免其受阴影干扰。

表 1 多光谱相机参数及灰板对其中心波长的反射率

Tab.1 Parameters of multispectral camera and reflectivity of calibrated reflectance panel to its center wavelength

波段序号	波段名称	中心波长/nm	波宽/nm	灰板反射率/%
1	蓝光	475	20	53.8
2	绿光	560	20	53.8
3	红光	668	10	53.5
4	近红外	840	40	53.0
5	红边	717	10	53.4

筛选出包含试验区的单幅影像,使用 Agisoft LCC 公司开发的 PhotoScan 软件进行拼接,得到试验区各波段正射影像。将拼接好的各波段影像导入 ArcGIS,采用

$$R_i = \frac{D_i}{D_{bi}} R_{bi} \tag{1}$$

式中 R_i ——地面目标第 i 波段反射率
 D_i ——地面目标第 i 波段 DN 值
 R_{bi} ——灰板第 i 波段反射率
 D_{bi} ——灰板第 i 波段 DN 值

进行辐射定标,将图像数字量化值(Digital number, DN)转化为反射率,从而得到各波段反射率影像。

1.3 植被指数选取与计算

结合前人的研究成果,选取了 8 种植被指数用于估算夏玉米 SPAD 值。各个植被指数的公式及来源如表 2 所示。

表 2 植被指数汇总

Tab.2 Definitions of vegetation indices

植被指数	计算公式	文献序号
归一化植被指数 (NDVI)	$NDVI = (NIR - RED) / (NIR + RED)$	[18]
绿色归一化植被指数 (GNDVI)	$GNDVI = (NIR - Green) / (NIR + Green)$	[19]
比值植被指数 (RVI)	$RVI = NIR / RED$	[20]
土壤调节植被指数 (OSAVI)	$OSAVI = 1.16 (NIR - RED) / (NIR + RED + 0.16)$	[21]
修正叶绿素吸收反射率植被指数 (MCARI)	$MCARI = [REG - RED - 0.2 (REG - Green)] REG / RED$	[22]
改进的简单比值指数 (MSR)	$MSR = (NIR / RED - 1) / \sqrt{NIR / RED + 1}$	[23]
红边叶绿素指数 (CI _{re})	$CI_{re} = NIR / REG - 1$	[24]
作物氮反射指数 (NRI)	$NRI = (Green - RED) / (Green + RED)$	[25]

注:NIR、RED、Green、REG 分别为近红外波段、红光波段、绿光波段、红边波段的反射率。

基于各波段反射率影像计算得到植被指数。进一步,采用植被指数阈值法剔除土壤背景,通过目视解译的方式确定每个植被指数中植被与土壤背景的阈值,经栅格计算器运算后剔除土壤背景。根据试验小区位置和大小构建矢量文件,统计矢量范围内

植被指数的均值作为这一小区的植被指数。以上过程均在 ArcGIS 中完成。

1.4 田间数据获取

在无人机影像采集的同时进行 SPAD 的测量。使用 SPAD-502Plus 便携式叶绿素测定仪测量植株

的穗位叶,在叶子中部避开叶脉随机选取 5 个位置测定,取平均值作为该植株的 SPAD 值,每个小区选 7 株进行测量,其平均值作为该小区的 SPAD 值。不同生育期获得的 SPAD 值样本特征如表 3 所示。

表 3 SPAD 值样本特征统计

Tab.3 Descriptive statistics of SPAD values

生育期	样本数	范围	平均值	标准差	变异系数/%
拔节期	21	47.5 ~ 59.0	54.7	3.24	5.93
抽雄期	21	46.4 ~ 64.1	58.4	4.90	8.39
灌浆期	21	50.1 ~ 69.4	63.2	5.46	8.64
全生育期	63	46.4 ~ 69.4	58.8	5.78	9.83

1.5 模型构建方法

偏最小二乘法 (Partial least squares, PLS) 是一种通过最小化误差的平方和寻找一组数据最佳匹配函数的方法。它将相关性分析、主成分分析和多元线性回归等统计方法有效地结合起来,可以在自变量具有多重相关性和样本点个数较少的条件下建立模型。

随机森林回归 (Random forest regression, RF) 是利用多个决策树对样本进行训练并预测的一种机器学习算法,有很强的抗干扰能力和抗过拟合能力。同时,还具有训练速度快、无需对输入数据做处理等优点。

分层线性模型 (Hierarchical linear model, HLM) 是由不同层次的自变量解释同一变量的一体化模型,是一种具有分层或嵌套数据结构的混合模型形式。在本研究中,采用包含两层的分层线性模型,第 1 层模型是基于植被指数的 SPAD 估算模型,第 2 层模型中因变量是第 1 层模型的截距和斜率,气象要

素 (降雨量、最高气温) 作为自变量,具体形式为

$$SPAD_{mj} = \psi_{0j} + \psi_{1j}OSAVI_{mj} + \psi_{2j}Clre_{mj} + e_{mj} \quad (2)$$

其中

$$\begin{cases} \psi_{0j} = \gamma_{00} + \gamma_{01}T_{maxj} + \gamma_{02}P_j + u_{0j} \\ \psi_{1j} = \gamma_{10} + \gamma_{11}T_{maxj} + \gamma_{12}P_j + u_{1j} \\ \psi_{2j} = \gamma_{20} + \gamma_{21}T_{maxj} + \gamma_{22}P_j + u_{2j} \end{cases} \quad (3)$$

式中 ψ_{0j} ——第 1 层模型的截距
 ψ_{1j} 、 ψ_{2j} ——OSAVI、Clre 的斜率
 e_{mj} ——随机误差
 T_{maxj} 、 P_j ——最高气温、降雨量
 γ_{00} 、 γ_{10} 、 γ_{20} ——第 2 层模型的截距
 γ_{01} 、 γ_{11} 、 γ_{21} ——最高气温的斜率
 γ_{02} 、 γ_{12} 、 γ_{22} ——降雨量的斜率
 u_{0j} 、 u_{1j} 、 u_{2j} ——随机误差

1.6 模型精度评价

采用决定系数 (Coefficient of determination, R^2)、均方根误差 (Root mean square error, RMSE) 和相对分析误差 (Relative prediction deviation, RPD) 3 个指标评价模型反演精度。其中, R^2 越大, RMSE 越小, 表明模型效果越好。而 RPD 对模型的评价分为 3 个等级: 当 $RPD < 1.4$ 时, 认为模型无法对样本进行预测; $1.4 \leq RPD < 2$ 时, 认为模型效果一般, 可以用来对样本进行粗略预测; $RPD \geq 2$ 时, 认为模型具有极好的预测能力。

2 结果与分析

2.1 SPAD 与植被指数的相关性分析

计算得到拔节期、抽雄期和灌浆期不同试验处理下各小区的 8 个植被指数, 与相对应的田间实测 SPAD 组成数据集。分别对这 3 个生育期的 SPAD 与植被指数进行相关性分析, 结果如图 3 所示。




图 3 植被指数与 SPAD 的相关系数

Fig.3 Correlation coefficients between vegetation indices and SPAD values

由图 3 可知,在 3 个生育期,NDVI、GNDVI、RVI、OSAVI、MSR 和 Clre 与 SPAD 均呈正相关关系,而 MCARI、NRI 与 SPAD 之间均是负相关关系。从图 3a 中可以看出,在拔节期,NDVI、RVI、OSAVI、

MSR、Clre 的相关系数为 0.59 ~ 0.77,在 0.01 水平上显著;GNDVI、MCARI 与 SPAD 有较低的相关性,相关系数分别为 0.52 和 -0.49,在 0.05 水平上相关性显著;NRI 与 SPAD 的相关系数只有 -0.03,关

系不显著。由图 3b 可知,在抽雄期,OSAVI 与 SPAD 的相关系数最高,为 0.63;NRI 最低,为 -0.35。GNDVI与 SPAD 的相关性在 0.05 水平上显著,NRI 不显著,其余在 0.01 水平上显著。由图 3c 可以看出,在灌浆期,NRI 与 SPAD 的相关系数仍旧是最低的,为 -0.35,相关关系不显著;除此之外的植被指数与 SPAD 均具有较强的相关关系,在 0.01 水平上显著,其中,CIre 与 SPAD 的相关系数最高,为 0.74。

综合来看,NRI 与 SPAD 的相关性较差;其余植被指数与 SPAD 呈现较强且稳定的相关关系,均能达到 0.05 水平上显著。

2.2 反演建模

利用 PLS、RF 分别建立拔节期、抽雄期、灌浆期的 SPAD 反演模型,采用 PLS、RF 和 HLM 分别建立全生育期 SPAD 的估算模型,建模和验证结果如表 4

所示。PLS、RF、HLM 模型预测值和实测值的关系分别如图 4~6 所示。

表 4 不同估算模型的建模和验证结果
Tab.4 Calibration and validation results of different estimation models

建模方法	生育期	建模集		验证集		
		R^2	RMSE	R^2	RMSE	RPD
PLS	拔节期	0.53	2.34	0.74	1.46	1.94
	抽雄期	0.38	3.67	0.35	4.29	1.24
	灌浆期	0.62	3.13	0.69	3.35	1.81
	全生育期	0.68	3.44	0.51	3.56	1.43
RF	拔节期	0.91	1.00	0.81	1.24	2.30
	抽雄期	0.89	1.55	0.81	2.32	2.29
	灌浆期	0.89	1.71	0.73	3.13	1.94
	全生育期	0.83	2.51	0.61	3.20	1.60
HLM	全生育期	0.72	3.20	0.55	3.41	1.52




图 4 基于偏最小二乘法的 SPAD 估算模型预测值和实测值的关系

Fig.4 Relationships between predicted values of SPAD based on partial least squares method and measured values

基于 SPAD 与植被指数的相关性分析结果,选择 NDVI、GNDVI、RVI、OSAVI、MCARI、MSR、CIre 这 7 个植被指数进行 PLS 和 RF 建模。从表 4 中可以看出,同一方法对不同生育期 SPAD 的反演效果存在差异,同一生育期中不同方法的表现也不同。就生育期来看,在拔节期,RF 模型的建模集 R^2 为

0.91,验证集 R^2 为 0.81,均高于 PLS 建模集和验证集的 R^2 ;RF 模型建模集和验证集的 RMSE 均低于 PLS 模型,分别为 1.00 和 1.24;RF 模型的 RPD 大于 2,PLS 模型的 RPD 为 1.94,说明 RF 模型对 SPAD 具有极好的预测能力,而 PLS 模型效果一般,可以对 SPAD 进行粗略估计。在抽雄期,RF 模型的




图 5 基于随机森林的 SPAD 估算模型预测值和实测值的关系

Fig. 5 Relationships between predicted values of SPAD based on random forest and measured values




图 6 基于分层线性模型的 SPAD 估算模型预测值和实测值的关系

Fig. 6 Relationships between predicted values of SPAD based on hierarchical linear model and measured values

建模集和验证集 R^2 分别比 PLS 模型高 0.51 和 0.46, RMSE 分别低 2.12 和 1.97, RPD 显示 RF 模型具有极好的预测能力,而 PLS 模型无法对 SPAD 进行预测。在灌浆期,RF 模型各个评价指标均表明 RF 模型精度比 PLS 模型高,其中,两个模型在验证集上表现出差不多的效果,两个模型均为一般模型。就建模方法来看,和 PLS 模型相比,RF 模型对各生

育期的 SPAD 反演效果都有不同程度的提升,尤其是在抽雄期。PLS 和 RF 模型精度均在拔节期为最高,PLS 模型在抽雄期表现最差,验证集 R^2 只有 0.35,不能用来反演 SPAD,而 RF 模型在各生育期表现较为稳定,在灌浆期反演精度相对较低。

由于用以上 7 个植被指数进行 HLM 建模时,出现过拟合现象,建立的模型在验证集上效果很差,所以基于 SPAD 与植被指数的相关性分析和 RF 模型的变量重要性分析,选择 OSAVI 和 CI_{re} 作为输入变量建立 HLM 模型。在全生育期,不论是建模集还是验证集, R^2 从大到小依次为 RF、HLM、PLS, RMSE 从小到大分别为 RF、HLM、PLS, RPD 从大到小为 RF、HLM、PLS,说明相比之下 RF 模型对 SPAD 的反演效果最好、精度最高,但 3 个模型对 SPAD 的反演效果均一般,只能进行粗略估计。

2.3 基于最佳估算模型的 SPAD 可视化制图

与分生育期模型相比,全生育期模型在各生育期的预测精度有所降低,所以将分生育期 RF 模型应用到各生育期,得到不同生育期试验地各小区的 SPAD 空间分布图,如图 7 所示。

整体上呈现出从拔节期到抽雄期再到灌浆期 SPAD 持续增大的趋势,这与实测结果一致。在不




图 7 不同生育期 SPAD 空间分布图

Fig.7 SPAD spatial distribution maps in different growth stages

同生育期,CK 处理的 SPAD 均最小,集中在 48.5 ~ 52;不同施氮处理,N1 处理的 SPAD 较低,而 N2 和 N3 处理的比较相近;相同施氮水平下的追肥与不追肥处理差异不明显。图 7 中信息与实际测量结果的规律一致,说明基于无人机多光谱影像建立经验模型进行田块尺度夏玉米 SPAD 估算是可行的。

3 讨论

本研究基于无人机获取的多光谱影像提取 8 个植被指数,经筛选后作为模型输入变量,利用 PLS、RF 分别建立拔节期、抽雄期和灌浆期的 SPAD 反演模型,采用 PLS、RF 和 HLM 进行全生育期 SPAD 建模。

CI_{re} 与 SPAD 的相关系数波动大,且在灌浆期明显高于其他植被指数。CI_{re} 是红边波段和近红外波段构建的植被指数。首先,HORLER 等^[26]研究发现波长 700 nm 左右的反射率与叶绿素有良好的相关性,这使得 CI_{re} 与 SPAD 具有强相关性。其次,红边波段对叶绿素含量的变化非常敏感^[27],在植被指数中引入红边波段,可以增强其对叶绿素含量变化的敏感性^[28]。此外,红边波段参与构建的植被指数多数容易受外界环境因素的影响^[29-30]。因此,CI_{re} 与 SPAD 的相关性又具有不稳定性。

各个生育期的最优模型均是 RF 模型,主要原因是随机森林算法自身的优越性^[31]。它对数据的包容力强,并且随机选取数据和待选特征,构建多个决策树对样本进行训练,最终取每个决策树预测值的平均值作为最终结果,因此,使得模型具有较高的精度以及很强的抗干扰能力^[32-33]。RF 模型在很多研究中都表现较好,姚雄等^[34]研究表明 RF 模型为马尾松林叶面积指数的最佳估测模型,程千等^[35]利用无人机多时相植被指数估测冬小麦产量,RF 模型

估测精度最高,且稳定性更好。偏最小二乘法和随机森林回归都在拔节期达到最佳,原因可能是拔节期数据分布好,变异系数小,而到夏玉米生育中后期对照组和施肥的 SPAD 值差距拉大,变异系数增大。

HLM 模型结合了夏玉米生育期的气象数据(降雨量、最高气温)和多光谱数据,就本研究来看,HLM 模型介于 PLS 模型和 RF 模型之间。相比于 PLS 模型,HLM 模型对 SPAD 估算精度有所提升,而和 RF 模型相比,HLM 模型精度稍差一些。这与已有研究结果相类似,HLM 模型可以一定程度提升线性模型的估算精度和稳定性^[15-17]。

分层线性模型为无人机遥感数据估算 SPAD 提供了新的方向,同时它也存在着巨大的潜力。本研究中,HLM 模型融合了降雨量和最高气温这两个气象因子,还应进一步关注其他气象参数对 SPAD 的影响,例如太阳辐射,从而提高 SPAD 估算精度。同时,如果考虑更多的输入参数,HLM 模型的复杂性将增加,所以如何平衡好模型的精度和复杂程度也是一个值得探究的问题。

4 结论

(1)在本研究选取的 8 个植被指数中,除 NRI 之外,NDVI、OSAVI、GNDVI、RVI、MCARI、MSR、CI_{re} 与 SPAD 均显著相关。其中,OSAVI、NDVI 与 SPAD 呈现出较强且稳定的相关性,在拔节期、抽雄期和灌浆期的相关系数都较高;灌浆期,CI_{re} 表现突出,相关系数达到 0.74。

(2)各个生育期的最优模型均是 RF 模型,在拔节期、抽雄期、灌浆期和全生育期,验证集 R^2 分别为 0.81、0.81、0.73、0.61, RMSE 分别为 1.24、2.32、3.13、3.20。和 PLS 模型相比,RF 模型在抽雄期极

大提升了估算精度,PLS 模型验证集的 R^2 、RMSE、RPD 分别为 0.35、4.29、1.24,RF 模型的 R^2 、RMSE、RPD 分别为 0.81、2.32、2.29。

(3) PLS 模型在各生育期表现不稳定,特别是在抽雄期,精度最低,而 RF 模型在各生育期表现较为稳定,PLS 和 RF 模型精度均在拔节期为最高。与各

生育期分别建立的估算模型相比,全生育期模型的估算精度有所降低。

(4) 对于 SPAD 估算模型,将降雨量、最高气温这两个气象因子与植被指数耦合的 HLM 模型可以一定程度提升线性模型的估算精度和稳定性,但其精度低于 RF 模型。

参 考 文 献

- [1] 史舟,梁宗正,杨媛媛,等. 农业遥感研究现状与展望[J]. 农业机械学报, 2015, 46(2): 247–260.
SHI Zhou, LIANG Zongzheng, YANG Yuanyuan, et al. Status and prospect of agricultural remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(2): 247–260. (in Chinese)
- [2] 赵春江. 智慧农业的发展现状与未来展望[J]. 华南农业大学学报, 2021, 42(6): 1–7.
ZHAO Chunjiang. Current situations and prospects of smart agriculture[J]. Journal of South China Agricultural University, 2021, 42(6): 1–7. (in Chinese)
- [3] 唐华俊. 农业遥感研究进展与展望[J]. 农学学报, 2018, 8(1): 167–171.
TANG HuaJun. Progress and prospect of agricultural remote sensing research[J]. Journal of Agriculture, 2018, 8(1): 167–171. (in Chinese)
- [4] 陈浩,冯浩,杨桢婷,等. 基于无人机多光谱遥感的夏玉米冠层叶绿素含量估计[J]. 排灌机械工程学报, 2021, 39(6): 622–629.
CHEN Hao, FENG Hao, YANG Zhenting, et al. Estimation of chlorophyll content of summer maize canopy based on UAV multispectral remote sensing[J]. Journal of Drainage and Irrigation Machinery Engineering, 2021, 39(6): 622–629. (in Chinese)
- [5] 陈小龙,陈灿,周莉. 水稻不同生育期叶绿素含量的测定及其相关性分析[J]. 现代农业科技, 2010(17): 42–44, 52.
CHEN Xiaolong, CHEN Can, ZHOU Li. Determination and correlativity analysis of chlorophyll content at different developmental stages in rice[J]. Modern Agricultural Science and Technology, 2010(17): 42–44, 52. (in Chinese)
- [6] 王薇,宋廷宇,王艳,等. 番茄叶片 SPAD 值与叶绿素含量的相关性分析[J]. 北方园艺, 2013(23): 12–15.
- [7] GRADOS D, REYNARFAJE X, SCHREVEENS E. A methodological approach to assess canopy NDVI-based tomato dynamics under irrigation treatments[J]. Agricultural Water Management, 2020, 240: 106208.
- [8] 徐晋,蒙继华. 农作物叶绿素含量遥感估算的研究进展与展望[J]. 遥感技术与应用, 2016, 31(1): 74–85.
XU Jin, MENG Jihua. Overview on estimating crop chlorophyll content with remote sensing[J]. Remote Sensing Technology and Application, 2016, 31(1): 74–85. (in Chinese)
- [9] LOPEZ-CALDERON M J, ESTRADA-AVALOS J, RODRIGUEZ-MORENO V M, et al. Estimation of total nitrogen content in forage maize (*Zea mays* L.) using spectral indices: analysis by random forest[J]. Agriculture, 2020, 10(10): 451.
- [10] COLORADO J D, CERA-BORNACELLI N, CALDAS J S, et al. Estimation of nitrogen in rice crops from UAV-captured images[J]. Remote Sensing, 2020, 12(20): 3396.
- [11] 孟沌超,赵静,兰玉彬,等. 基于无人机可见光影像的玉米冠层 SPAD 反演模型研究[J]. 农业机械学报, 2020, 51(增刊 2): 366–374.
MENG Dunchao, ZHAO Jing, LAN Yubin, et al. SPAD inversion model of corn canopy based on UAV visible light image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 366–374. (in Chinese)
- [12] 乔浪,张智勇,陈龙胜,等. 基于无人机图像的玉米冠层叶绿素含量检测与分布研究[J]. 农业机械学报, 2019, 50(增刊): 182–186, 194.
QIAO Lang, ZHANG Zhiyong, CHEN Longsheng, et al. Chlorophyll content detection and distribution research of maize canopy based on UAV image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 182–186, 194. (in Chinese)
- [13] 牛庆林,冯海宽,周新国,等. 冬小麦 SPAD 值无人机可见光和多光谱植被指数结合估算[J]. 农业机械学报, 2021, 52(8): 183–194.
NIU Qinglin, FENG Haikuan, ZHOU Xinguo, et al. Combining UAV visible light and multispectral vegetation indices for estimating SPAD value of winter wheat[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 183–194. (in Chinese)
- [14] 田军仓,杨振峰,冯克鹏,等. 基于无人机多光谱影像的番茄冠层 SPAD 预测研究[J]. 农业机械学报, 2020, 51(8): 178–188.
TIAN Juncang, YANG Zhenfeng, FENG Kepeng, et al. Prediction of tomato canopy SPAD based on UAV multispectral image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 178–188. (in Chinese)
- [15] LI Z H, TAYLOR J, YANG H, et al. A hierarchical interannual wheat yield and grain protein prediction model using spectral vegetative indices and meteorological data[J]. Field Crops Research, 2020, 248: 107711.
- [16] ZHU B X, CHEN S B, CAO Y J, et al. A regional maize yield hierarchical linear model combining Landsat 8 vegetative

- indices and meteorological data: case study in Jilin Province[J]. Remote Sensing, 2021, 13(3): 356.
- [17] XU X B, TENG C, ZHAO Y, et al. Prediction of wheat grain protein by coupling multisource remote sensing imagery and ECMWF data[J]. Remote Sensing, 2020, 12(8): 1349.
- [18] ROUSE J W, HAAS R H, DEEING D W, et al. Monitoring the vernal advancement of retrogradation (green wave effect) of natural vegetation[M]. Texas A&M University: Remote Sensing Center, 1974.
- [19] 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.
- [20] SCHUERGER 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.
- [21] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. Remote Sensing of Environment, 1996, 55(2): 95 – 107.
- [22] 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): 416 – 426.
- [23] 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.
- [24] 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.
- [25] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. Remote Sensing of Environment, 1979, 8(2): 127 – 150.
- [26] HORLER D N H, DOCKRAY M, BARBER J. The red edge of plant leaf reflectance[J]. International Journal of Remote Sensing, 1983, 4(2): 273 – 288.
- [27] 秦占飞, 常庆瑞, 申健, 等. 引黄灌区水稻红边特征及 SPAD 高光谱预测模型[J]. 武汉大学学报(信息科学版), 2016, 41(9): 1168 – 1175.
- QIN Zhanfei, CHANG Qingrui, SHEN Jian, et al. Red edge characteristics and SPAD estimation model using hyperspectral data for rice in Ningxia Irrigation Zone[J]. Geomatics and Information Science of Wuhan University, 2016, 41(9): 1168 – 1175. (in Chinese)
- [28] 苏伟, 赵晓凤, 孙中平, 等. 基于 Sentinel – 2A 影像的玉米冠层叶绿素含量估算[J]. 光谱学与光谱分析, 2019, 39(5): 1535 – 1542.
- SU Wei, ZHAO Xiaofeng, SUN Zhongping, et al. Estimating the corn canopy chlorophyll content using the Sentinel – 2A image[J]. Spectroscopy and Spectral Analysis, 2019, 39(5): 1535 – 1542. (in Chinese)
- [29] 毛智慧, 邓磊, 孙杰, 等. 无人机多光谱遥感在玉米冠层叶绿素预测中的应用研究[J]. 光谱学与光谱分析, 2018, 38(9): 2923 – 2931.
- MAO Zhihui, DENG Lei, SUN Jie, et al. Research on the application of UAV multispectral remote sensing in the maize chlorophyll prediction[J]. Spectroscopy and Spectral Analysis, 2018, 38(9): 2923 – 2931. (in Chinese)
- [30] VINCINI M, AMADUCCI S, FRAZZI E. Empirical estimation of leaf chlorophyll density in winter wheat canopies using Sentinel – 2 spectral resolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6): 3220 – 3235.
- [31] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5 – 32.
- [32] 杨练兵, 陈春波, 郑宏伟, 等. 基于优化随机森林回归模型的土壤盐渍化反演[J]. 地球信息科学学报, 2021, 23(9): 1662 – 1674.
- YANG Lianbing, CHEN Chunbo, ZHENG Hongwei, et al. Retrieval of soil salinity content based on random forests regression optimized by Bayesian optimization algorithm and genetic algorithm[J]. Journal of Geo-information Science, 2021, 23(9): 1662 – 1674. (in Chinese)
- [33] 张子晗, 晏磊, 刘思远, 等. 基于偏振反射模型和随机森林回归的叶片氮含量反演[J]. 光谱学与光谱分析, 2021, 41(9): 2911 – 2917.
- ZHANG Zihan, YAN Lei, LIU Siyuan, et al. Leaf nitrogen concentration retrieval based on polarization reflectance model and random forest regression[J]. Spectroscopy and Spectral Analysis, 2021, 41(9): 2911 – 2917. (in Chinese)
- [34] 姚雄, 余坤勇, 刘健. 基于无人机多光谱遥感的马尾松林叶面积指数估测[J]. 农业机械学报, 2021, 52(7): 213 – 221.
- YAO Xiong, YU Kunyong, LIU Jian. Leaf area index estimation of Masson pine (*Pinus massoniana*) forests based on multispectral remote sensing of UAV[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 213 – 221. (in Chinese)
- [35] 程千, 徐洪刚, 曹引波, 等. 基于无人机多时相植被指数的冬小麦产量估测[J]. 农业机械学报, 2021, 52(3): 160 – 167.
- CHENG Qian, XU Honggang, CAO Yinbo, et al. Grain yield prediction of winter wheat using multi-temporal UAV based on multispectral vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 160 – 167. (in Chinese)