

基于无人机多光谱影像的水稻氮营养监测

凌琪涵¹, 孔发明^{1,2}, 宁强^{1,2}, 魏勇^{1,2}, 柳展³, 代明珠³, 周宇³,
张跃强^{1,2,4}, 石孝均^{1,2,4}, 王洁^{1,2,4*}

(1. 西南大学资源环境学院 重庆 400716; 2. 长江经济带农业绿色发展研究中心 重庆 400716; 3. 勐海曼香云天农业发展有限公司 勐海县 666205; 4. 国家紫色土肥力与肥料效益监测基地 重庆 400716)

摘要: 探究消费级无人机多光谱影像对不同生态点、不同品种水稻氮营养监测建模精确度和普适度的影响, 对于实现区域水稻氮营养精确管理与应用有重要意义。该研究分别在云南省西双版纳勐遮镇(供试品种: 云粳37)与重庆市北碚区(供试品种: 极优6135)2个试验点设置不同氮水平田间试验, 利用大疆精灵4多光谱无人机于水稻分蘖期、拔节期和抽穗期采集水稻冠层多光谱图像, 采用凯氏定氮法测定水稻植株冠层氮含量(canopy nitrogen content, CNC)并计算地上部氮累积量(plant nitrogen accumulation, PNA); 分别利用植被指数、偏最小二乘回归(partial least squares regression, PLSR)、随机森林(random forest, RF)、反向传播神经网络(back-propagation neural network, BPNN)对单一试验点、单品种和不同试验点、多品种水稻建立氮营养监测模型并探究模型的迁移能力。拔节期和抽穗期的模型精度较高(归一化植被指数NDVI或近红外归一化植被指数NNVI, R^2 为0.68~0.88), 而分蘖期的模型精度欠佳(NDVI, R^2 为0.53~0.79), 且模型迁移能力均较差; 通过RVI(ratio vegetation index)建立的单品种水稻全生育期地上部氮累积量监测的精度较高且迁移能力较好。基于PLSR、RF和BPNN构建的模型精度高于植被指数模型, 其中基于RF的多品种全生育期冠层氮含量和地上部氮累积量监测模型精度最高, R^2 分别为0.84和0.94, 均方根误差分别为0.28%和10.09 kg/hm²。研究结果可为无人机多光谱影像技术对不同生态点、不同品种的水稻全生育期氮营养监测提供理论依据和技术支持。

关键词: 无人机; 植被指数; 机器学习; 多光谱成像; 氮营养监测; 水稻

doi: 10.11975/j.issn.1002-6819.202302093

中图分类号: S147.2; S24

文献标志码: A

文章编号: 1002-6819(2023)-13-0160-11

凌琪涵, 孔发明, 宁强, 等. 基于无人机多光谱影像的水稻氮营养监测[J]. 农业工程学报, 2023, 39(13): 160-170. doi: 10.11975/j.issn.1002-6819.202302093 <http://www.tcsae.org>

LING Qihan, KONG Faming, NING Qiang, et al. Rice nitrogen nutrition monitoring based on unmanned aerial vehicle multispectral image[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2023, 39(13): 160-170. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202302093 <http://www.tcsae.org>

0 引言

氮是水稻生长发育必需的营养元素, 参与水稻体内重要化合物的合成并与产量密切相关, 氮肥施用不足或者过量均会影响水稻的生长发育进而影响产量和品质^[1]。大量研究表明, 利用不同尺度的遥感监测手段能实现水稻氮营养诊断和指导变量精准施氮, 然而大多数的研究仅仅建立了单一品种的氮营养监测模型, 缺乏对不同试验点、多品种水稻氮营养监测的探究。同时, 消费级无人机载传感设备的研究与应用不足, 以至于大部分研究结果难以推广使用。因此, 探究基于消费级无人机载多光谱成像技术对不同试验点、多品种水稻氮营养监测与应用具有重要意义。目前大多数水稻氮营养监测主要基于叶片尺度的地面遥感、无人机近地遥感以及星载遥

感^[2]。李卫国等^[3]在水稻分蘖期利用HJ-1A卫星遥感影像通过归一化植被指数(normalized difference vegetation index, NDVI)反演水稻叶面积指数(leaf area index, LAI), 并进行了水稻长势分级。然而, 卫星遥感存在空间分辨率较低、重访周期较长、受天气影响大等不足^[4]。地面遥感技术利用便携式地物光谱仪能够快速、准确的获取作物生长和营养等信息^[5]。李旭青等^[6]的研究结果表明, 以氮素光谱敏感指数作为输入变量结合随机森林算法构建水稻冠层氮含量反演模型精度较高(决定系数 R^2 为0.82)。于丰华等^[7]利用连续投影法提取敏感波段, 并采用波段特征转移思路, 筛选出3个敏感波段(550、729和800 nm)构成氮素特征转移指数, 利用线性回归模型构建了水稻叶片氮含量监测模型, R^2 为0.77, 均方根误差 R_{MSE} 为0.38 mg/g。但便携式地物光谱仪监测范围小、工作量较大, 很难实现田块尺度的作物营养监测和农情反演^[8]。近年来, 无人机遥感凭借空间分辨率高(可获取田块尺度厘米级遥感影像)、时效性强、成本低等优势, 在作物营养诊断领域迅速普及^[9]。目前, 无人机作物氮营养监测主要通过植被指数的经验模型、化学计量法和机器学习等方式实现^[10]。王玉娜等^[11]通过分析小麦冠层光谱参数与植株氮含量、地上部生物

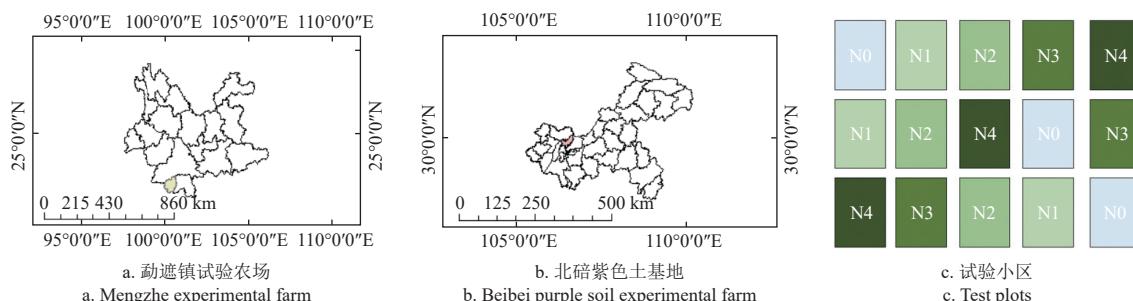
收稿日期: 2023-02-16 修订日期: 2023-04-17

基金项目: 云南现代农业绿色关键技术创新与平台建设项目(202102AE090053); 国家自然科学基金项目(31801932)

作者简介: 凌琪涵, 研究方向为植物营养无损诊断研究。Email: 2502035800@qq.com

*通信作者: 王洁, 博士, 讲师, 研究方向为植物营养遥感反演、果树养分资源管理、智慧农业系统设计与开发。Email: mutouyu@swu.edu.cn

量和氮素营养指数的相关性, 筛选出3个敏感光谱参数, 通过随机森林构建冬小麦氮素营养指数模型, 模型的决定系数为0.79, 均方根误差为0.13。冯帅等^[12]筛选敏感波段两两随机组合构建植被指数, 实现了各生育期东北粳稻冠层叶片氮含量估测, 结果较为准确(R^2 均大于0.70)。魏鹏飞等^[13]通过以各生育期最优光谱指数为自变量, 夏玉米叶片氮含量为因变量, 通过逐步回归建立夏玉米各生育期叶片氮含量监测模型(R^2 为0.56~0.64)。WANG等^[14]系统总结了水稻氮营养监测建模方法, 发现植被指数模型较适用于单一生长阶段, 当涉及多个生育期混合样本时, 利用偏最小二乘回归和机器学习等方法对水稻叶片氮含量和地上部氮累积量建模精度(R^2 为0.72~0.95)优于植被指数(R^2 为0.62~0.87)。综上所述, 前人利用地面便携式光谱仪、无人机结合多/高光谱相机实现了水稻氮营养估测。然而, 无论是便携式地物光谱仪还是无人机载多/高光谱传感设备均花费巨大, 在一定程度上限制了其在农业上的应用。消费级无人机多光谱影像是近几年无人机近地遥感监测设备的重大技术突破, 所搭载传感器光谱波段较全面, 性价比很高, 配套简便易操作的图像处理与分析软件, 在规模化田块尺度农情监测方面发展迅速。然而, 利用无人机多光谱影像在单一试验点、单品种以及不同试验点、多品种水稻氮营养监测的研究鲜有报道。本研究利用消费级无人机多光谱遥感技术, 获取2个试验点不同品种水稻分蘖期、拔节期、抽穗期的冠层多光谱图像, 测定水稻冠层氮含量和地上部氮累积量, 通过植被指数、偏最小二乘回归、随机森林以及反向传播神经网络, 探究单一试验点、单一品种水稻和不同试验点、多品种水稻氮营养监测, 以期为无人机载多光谱遥感技术在不同试验点、不同品种水稻氮营养监测和指导精确施氮提供理论依据和技术支持。



注: N0~N4表示不同施氮量处理。

Note: N0-N4 represent treatments with different nitrogen application rates.

图1 试验农场及小区设计
Fig.1 Experimental farm and plot design

表1 各处理肥料施用量

Treatment	Mengzhe town experimental farm			Beibei purple soil base		
	N	P ₂ O ₅	K ₂ O	N	P ₂ O ₅	K ₂ O
	0	120	105	0	120	105
N0	0	120	105	0	120	105
N1	64	120	105	60	120	105
N2	128	120	105	120	120	105
N3	160	120	105	160	120	105
N4	192	120	105	200	120	105

1.2 水稻冠层多光谱图像采集与氮营养测定

利用大疆无人机精灵4多光谱版进行水稻冠层多光

1 材料与方法

1.1 试验设计

本研究分别在云南省西双版纳傣族自治州勐海县勐遮镇试验农场(简称勐遮镇试验农场, 100°13'E, 21°57'N, 海拔1265.08 m)与重庆市北碚区国家紫色土肥力与肥料效益监测基地(简称北碚紫色土基地, 106°26'E, 30°26'N, 海拔317 m)设置水稻不同施氮水平田间试验(图1)。勐遮镇试验农场属于热带季风气候, 年平均温度为24.01 °C, 年平均降雨量为1526.2 mm, 试验前土壤pH值5.3, 全氮1.20 g/kg, 速效磷37.70 mg/kg, 速效钾52.20 mg/kg, 有机质23.70 g/kg; 供试的水稻品种为云粳37。2021年1月15日播种, 采用人工插秧, N0~N4处理的施氮量分别为0、64、128、160、192 kg/hm²(见表1, N2为当地推荐施氮量, N3为农户施氮量)。

北碚紫色土基地属于亚热带湿润季风气候, 年平均温度为18.5 °C, 年平均降雨量为1105.1 mm, 试验前土壤pH值7.7, 全氮1.25 g/kg, 速效磷4.30 mg/kg, 速效钾88.45 mg/kg, 有机质22.61 g/kg; 供试的水稻品种为极优6135。2022年3月15日播种, 采用人工插秧的方式, N0~N4处理的施氮量分别为0、60、120、160、200 kg/hm²(见表1, N2为当地推荐施氮量, N3为农户施氮量)。每个小区50 m², 不同试验点水稻均实行单季种植制度, 株距13.3 cm、行距30 cm, 25万穴/hm², 每穴定植2株, 移栽基本苗50万株/hm²。云粳37分别在播种前、拔节期、抽穗期, 极优6135分别在播种前、分蘖期、拔节期施用尿素, 均按照总氮量的40%、40%、20%施用, 磷肥和钾肥分别作为基肥施用, P₂O₅用量120 kg/hm², K₂O用量105 kg/hm²(表1)。

谱图像采集, 采集时间为分蘖期、拔节期和抽穗期。选择天气晴朗无风、太阳光照强烈的10:00~14:00采集图像, 每次飞行前用漫反射灰布进行辐射定标。无人机垂直地面飞行, 飞行高度100 m, 航向重叠率80%, 旁向重叠率70%。相机每个航点自动拍照, 图像以TIFF格式保存。

在获取水稻冠层多光谱图像的同时, 从每个小区采集具有代表性水稻植株6穴带回实验室, 按照茎、叶、穗单独分装标记。将各时期的水稻样品放入烘箱, 105 °C杀青30 min后, 在70 °C的温度下烘干至恒质量。称量

后记录干质量, 然后用球磨仪将其粉碎, 称取烘干磨碎后的叶片、茎秆、穗样品 0.5 g, 采用凯氏定氮法测得水稻叶片、茎秆、穗的含氮量。

1.3 图像处理与数据计算

采集的多光谱图像包含 5 个光谱波段 (450、560、650、730 和 840 nm)。图像在 DJI TerraV3.6.0 中进行二维多光谱重建并添加漫反射辐射校正参数, 输出 5 个波段的多光谱正射图像, 对分蘖期图像进行掩膜处理, 去除土壤背景值, 再提取水稻冠层光谱值。

分蘖期和拔节期水稻全氮含量、氮累积量计算式为

$$\text{冠层氮含量} = \text{叶片全氮含量} \quad (1)$$

$$\text{地上部氮累积量} = \text{叶片全氮含量} \times \text{叶片干物质量} +$$

$$\text{茎秆全氮含量} \times \text{茎秆干物质量} \quad (2)$$

抽穗期水稻全氮含量、氮累积量计算式为

$$\text{冠层氮含量} = (\text{叶片全氮含量} \times \text{叶片干物质量} +$$

$$\text{穗全氮含量} \times \text{穗干物质量}) / (\text{叶片干物质量} + \text{穗干物质量}) \quad (3)$$

$$\text{地上部氮累积量} = \text{叶片全氮含量} \times \text{叶片干物质量} +$$

$$\text{茎秆全氮含量} \times \text{茎秆干物质量} +$$

$$\text{穗全氮含量} \times \text{穗干物质量} \quad (4)$$

1.4 数据分析与建模

数据集的划分利用 python 3.8 SKlearn 机器学习库的 train_test_split 算法 (*K-fold*), 将总样本随机划分为建模集 (70%) 和验证集 (30%)。根据前人研究选取与水稻氮营养相关性较高的比值植被指数 (ratio vegetation index, RVI^[15])、归一化植被指数 (normalized differ-

ence vegetation index, NDVI^[16])、归一化近红外植被指数 (normalized nir vegetation index, NNVI^[17]), 采用偏最小二乘回归 (partial least squares regression, PLSR^[18])、随机森林 (random forest, RF^[19]) 和反向传播神经网络 (back-propagation neural network, BPNN^[19]) 分别对单一试验点、单品种水稻和不同试验点、多品种水稻的冠层氮含量和地上部氮累积量进行建模。在迁移学习验证中, 以云梗 37 的样本作为验证集测试极优 6135 各生育期及全生育期氮营养监测模型的迁移能力; 以极优 6135 的样本作为验证集测试云梗 37 各生育期及全生育期氮营养监测模型的迁移能力。采用决定系数 R^2 和均方根误差 R_{MSE} 评价模型。

植被指数模型的构建及模型的 R^2 、 R_{MSE} 计算采用 Microsoft Excel 2019 进行。PLSR 是利用主成分分析与典型关联分析相结合, 解决模型自变量和因变量的映射问题; RF 利用 Bootstrap 重抽样方法从原始样本中抽取多个样本, 对每个 Bootstrap 样本构建决策树, 然后将决策树中最好的结果作为最终预测结果; BPNN 在建模前对变量进行归一化处理, 经过反复参数调试对数据进行训练, 最终确定隐含层节点数为 3、输出层节点数为 1 时模型最佳。PLSR 和 RF 模型在 python 3.8 的 Anaconda3 环境中采用 Sklearn 机器学习库建立, BPNN 模型采用 TensorFlow 2.0 深度学习库建立。

2 结果与分析

2.1 不同施氮处理对水稻冠层反射率的影响

在不同施氮处理下, 不同试验点的水稻冠层反射率如图 2 所示。

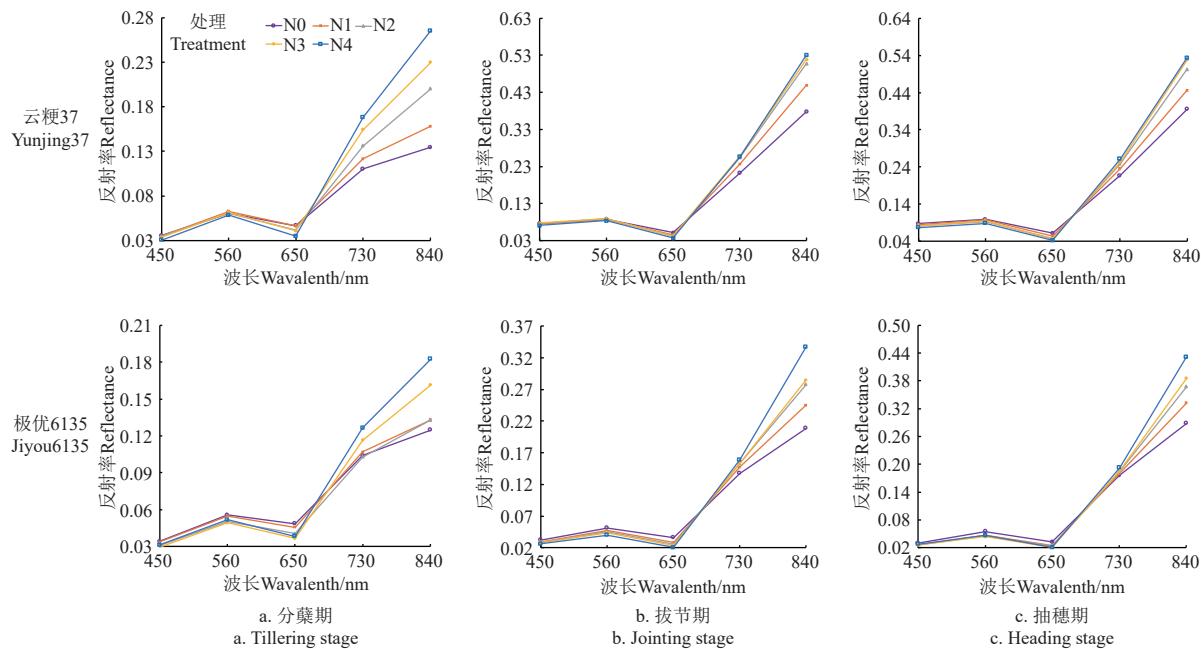


图 2 云梗 37 和极优 6135 不同生育期冠层反射率
Fig.2 Canopy reflectance of Yunjing 37 and Jiyou6135 at different growth stages

各生育期不同品种水稻的光谱反射率有明显差异。总体而言, 云梗 37 各波段光谱反射率均大于极优 6135, 尤其在 840 nm 处存在明显差异。其中, 拔节期云梗 37 在 840 nm 处的平均光谱反射率比极优 6135 高 0.21, 其

次是抽穗期 (840 nm 处平均光谱反射率差值为 0.12), 差值最小的为分蘖期 (840 nm 处平均光谱反射率差值为 0.08)。在不同施氮处理下, 不同品种在同一生育期的光谱反射率存在相似性。在分蘖期, 云梗 37 和极优 6135

光谱反射率变幅在整个波段范围内均随施氮量增加而增大(0.002~0.13; 0.003~0.05), 在可见光波段光谱反射率均随施氮量的增加而减小, 而在红边和近红外波段随施氮量的增加而增加。在拔节期和抽穗期, 均随施氮量增加而增加, 可见光光谱反射率变幅差异减小(0.004~0.015; 0.009~0.02), 而红边和近红外波段随施氮量的增加而增大(0.021~0.15; 0.02~0.14), 光谱反射率增加。

2.2 单一试验点、单品种水稻的冠层氮含量、地上部氮累积量反演模型验证

单一试验点、单品种水稻的各项生化指标见表2。总体而言, 随着生育期的进行, 2个品种冠层氮含量逐渐降低而地上部氮累积量逐渐升高。其中, 云梗37冠层氮含

量随生育期的降幅(0.87个百分点)小于极优6135(1.80个百分点), 且地上部累积量的增幅(35.34 kg/hm²)也小于极优6135(95.81 kg/hm²)。极优6135的氮营养在同一生育期均大于云梗37(除抽穗期冠层氮含量), 不同品种间冠层氮含量差异(0.76个百分点)小于地上部氮累积量(62.43 kg/hm²)。在分蘖期, 极优6135的冠层氮含量和地上部氮累积量比云梗37分别高0.76个百分点和1.99 kg/hm²。在拔节期, 极优6135的冠层氮含量和地上部氮累积量比云梗37分别高0.03个百分点和8.79 kg/hm²。在抽穗期, 极优6135的冠层氮含量比云梗37低0.17个百分点, 地上部氮累积量比云梗37高62.43 kg/hm²。在全生育期, 极优6135的冠层氮含量和地上部氮累积量比云梗37分别高0.18个百分点和30.27 kg/hm²。

表2 云梗37和极优6135不同生育期冠层氮含量和地上部氮累积量

Table 2 Canopy nitrogen content(CNC) and plant nitrogen accumulation(PNA) at different growth stages of yunjing37 and jiyou6135

生育期 Growth stage	指标 Index	云梗37Yunjing37				极优6135Jiyou6135			
		范围 Range	平均值 Average	变异系数 Coefficient of variation/%	样本数 Sample number	范围 Range	平均值 Average	变异系数 Coefficient of variation/%	样本数 Sample number
分蘖期 Tillering stage	CNC/%	2.00~3.65	2.90	12.75	87	3.02~4.34	3.66	10.00	79
	PNA /(kg·hm ⁻²)	3.30~30.12	16.74	39.20	87	10.07~29.14	18.73	30.57	79
拔节期 Jointing stage	CNC/%	2.16~3.29	2.73	11.53	72	2.03~3.46	2.75	15.92	84
	PNA /(kg·hm ⁻²)	14.41~84.72	49.63	37.06	72	20.63~111.66	58.42	49.71	84
抽穗期 Heading stage	CNC/%	1.43~2.38	2.03	12.20	81	1.36~2.33	1.86	16.57	90
	PNA /(kg·hm ⁻²)	20.58~74.2	52.08	22.91	81	36.7~183.52	114.51	41.87	90
全生育期 The whole growing stage	CNC/%	1.43~3.30	2.55	18.85	240	1.36~4.34	2.73	30.16	253
	PNA /(kg·hm ⁻²)	3.65~84.72	38.53	53.90	240	10.07~183.52	66.80	77.39	253

在水稻的3个生育期, 利用植被指数NDVI(840 nm, 650 nm), NNDVI, RVI(840 nm, 650 nm)建立单一试

验点、单品种氮营养监测模型, 对单一生育期的模型进行迁移学习验证, 结果如表3所示。

表3 不同生育期云梗37和极优6135冠层氮含量、地上部氮累积量测试集预测精度和迁移学习验证

Table 3 Validation of prediction accuracy and transfer learning of CNC and PNA test sets of Yunjing37 and Jiyou 6135 at different growth stages

生育期 Growth stage	建模指数 Modeling index	CNC				PNA					
		云梗37 Yunjing37		极优6135 Jiyou6135		迁移验证 Transfer validation		云梗37 Yunjing37		极优6135 Jiyou6135	
		R ²	R _{MSE} /%	R ²	R _{MSE} /%	T _{RMSE1} †/%	T _{RMSE2} ††/%	R ²	R _{MSE} /(kg·hm ⁻²)	R ²	R _{MSE} /(kg·hm ⁻²)
分蘖期 Tillering stage	NDVI	0.72	0.18	0.62	0.22	1.07	1.04	0.73	3.31	0.79	2.67
	NNVI	0.53	0.21	0.60	0.22	1.29	1.05	0.64	3.92	0.69	3.20
	RVI	0.57	0.23	0.61	0.22	1.15	1.00	0.68	3.55	0.74	2.91
拔节期 Jointing stage	NDVI	0.71	0.16	0.74	0.22	0.25	0.30	0.71	9.99	0.84	12.05
	NNVI	0.84	0.12	0.74	0.22	1.38	0.87	0.88	6.90	0.85	11.32
	RVI	0.73	0.13	0.72	0.23	1.02	0.26	0.67	9.65	0.80	12.16
抽穗期 Heading stage	NDVI	0.68	0.12	0.67	0.23	0.58	0.50	0.83	5.44	0.78	21.43
	NNVI	0.60	0.13	0.75	0.22	0.27	0.33	0.68	7.24	0.83	20.96
	RVI	0.54	0.14	0.72	0.23	0.90	0.81	0.78	6.02	0.78	22.39
全生育期 The whole growing stage	NDVI	NA	—	NA	—	—	—	0.77	12.44	0.60	62.87
	NNVI	NA	—	NA	—	—	—	0.48	8.44	0.70	28.78
	RVI	NA	—	NA	—	—	—	0.77	10.87	0.62	29.62
	RF	0.70	0.26	0.91	0.25	0.67	0.90	0.91	6.12	0.94	12.34
	PLSR	0.64	0.28	0.61	0.50	2.31	1.27	0.90	6.18	0.93	13.49
BPNN	0.67	0.27	0.63	0.49	2.30	1.27	0.89	6.80	0.93	13.30	37.54
	BPNN	0.67	0.27	0.63	0.49	2.30	1.27	0.89	6.80	0.93	42.45

注: NA表示模型R²小于0.01, “—”表示无法计算出R_{MSE}, T_{RMSE1}†指极优6135氮营养反演模型在云梗37的迁移验证均方根误差, T_{RMSE2}††指云梗37氮营养反演模型在极优6135的迁移验证均方根误差。

Note: NA means the models R² less than 0.01, “—” means can not be calculated R_{MSE}, T_{RMSE1} means the Jiyou6135 nitrogen nutrition (CNC and PNA) inversion models in Yunjing37, and T_{RMSE2} means the Yunjing37 nitrogen nutrition (CNC and PNA) inversion models in Jiyou6135.

总体而言, 拔节期和抽穗期利用植被指数构建的氮营养监测模型测试集精度均优于分蘖期, 在迁移测试中, 单一品种水稻、单生育期的测试迁移测试R_{MSE}较大。在分蘖期, 3种植被指数冠层氮含量监测模型的测试集R²为0.53~0.72, R_{MSE}为0.18%~0.23%; 地上部氮累积量监测模型的测试集R²为0.64~0.79, R_{MSE}为2.67~3.92 kg/hm², 其中NDVI的建模精度优于RVI和NNVI; 单一品种的分蘖期氮营养监测模型迁移测试的CNC和

PNA的R_{MSE}范围是1.00%~1.29%和8.07~12.51 kg/hm², 误差较大。在拔节期, 植被指数模型对冠层氮含量和地上部氮累积量的预测精度较好, 其中NNVI模型的冠层氮含量(R²为0.71~0.84, R_{MSE}为0.13%~0.23%)和地上部氮累积量(R²为0.67~0.88, R_{MSE}为6.90~12.16 kg/hm²)模型优于RVI和NDVI; 单一品种拔节期氮营养监测模型迁移测试的CNC和PNA的R_{MSE}为0.25%~1.38%和20.00~101.96 kg/hm²。在抽穗期, 云

粳 37 通过 NDVI 建立的冠层氮含量和地上部氮累积量模型的测试集精度较好, CNC 的 R^2 为 0.68 和 R_{MSE} 为 0.12%, PNA 的 R^2 为 0.83 和 R_{MSE} 为 $5.44 \text{ kg}/\text{hm}^2$; 极优 6135 通过 NNNI 建立的冠层氮含量和地上部氮累积量模型精度较好, CNC 的 R^2 为 0.75 和 R_{MSE} 为 0.22%, PNA 的 R^2 为 0.83 和 R_{MSE} 为 $20.96 \text{ kg}/\text{hm}^2$; 单一品种抽穗期氮营养监测模型迁移测试的 CNC 和 PNA 的 R_{MSE} 范围是 0.33%~0.90% 和 $35.37\sim125.24 \text{ kg}/\text{hm}^2$ 。

由表 3 可知, 基于 3 种植被指数无法建立云粳 37 和极优 6135 的全生育期冠层氮含量模型, 而 3 种植被指数可以建立水稻地上部氮累积量的模型。其中, RVI 地上部氮累积量监测模型的验证集和迁移测试结果

较好, 优于 NDVI 和 NNNI, 云粳 37 的测试集 R^2 和 R_{MSE} 分别为 0.77 和 $10.87 \text{ kg}/\text{hm}^2$, 迁移测试的 R_{MSE} 为 $14.10 \text{ kg}/\text{hm}^2$; 极优 6135 的测试集 R^2 和 R_{MSE} 分别为 0.62 和 $29.64 \text{ kg}/\text{hm}^2$, 迁移测试的 R_{MSE} 为 $24.18 \text{ kg}/\text{hm}^2$ 。基于 RF、PLSR 和 BPNN 均可以建立单一品种全生育期氮营养监测模型, 其中 RF 建立的冠层氮含量模型的测试集 R^2 分别为 0.70 和 0.91, R_{MSE} 分别为 0.26% 和 0.25%, 地上部氮累积量监测模型的 R^2 分别为 0.91 和 0.94, R_{MSE} 分别为 6.12 和 $12.34 \text{ kg}/\text{hm}^2$, 而全生育期冠层氮含量监测模型无法实现迁移学习验证, 地上部氮累积量模型迁移学习的 R_{MSE} 较大。

各处理的氮营养反演结果如图 3 所示。

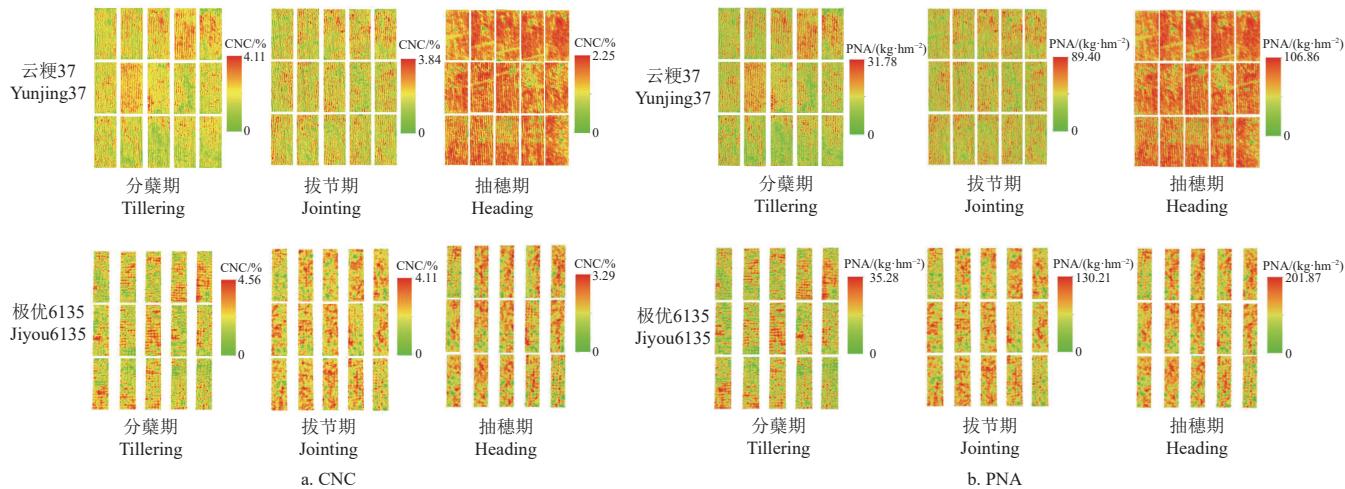


图 3 云粳 37 和极优 6135 冠层氮含量和地上部氮累积量反演结果
Fig.3 Results of CNC and PNA inversion of Yunjing 37 and Jiyou 6135

2.3 不同试验点、多品种水稻的冠层氮含量、地上部氮累积量反演模型验证

在 3 个生育期, 以植被指数、偏最小二乘回归 (PLSR)、随机森林 (RF) 以及反向传播神经网络 (BPNN) 对不同试验点、多品种的冠层氮含量、地上部氮累积量建立监测模型, 测试集结果如表 4 所示。

在 3 个生育期, 利用 PLSR、RF 和 BPNN 建立的不同试验点、多品种的冠层氮含量和地上部氮累积量监测模型的 R^2 为 $0.63\sim0.97$, 而植被指数无法建立水稻冠层氮含量监测模型, 可以建立地上部氮累积量监测模型, 但均存在较大误差, R_{MSE} 为 $6.82\sim73.76 \text{ kg}/\text{hm}^2$ 。在拔节期和抽穗期, 利用 PLSR、RF 和 BPNN 建立模型的精度均优于分蘖期。

在分蘖期, PLSR、RF 和 BPNN 构建的冠层氮含量监测模型测试集的 R^2 为 $0.43\sim0.57$, R_{MSE} 为 $0.34\%\sim0.39\%$; 地上部氮累积量监测模型的 R^2 为 $0.63\sim0.66$, R_{MSE} 为 $3.54\sim6.11 \text{ kg}/\text{hm}^2$, 其中 BPNN 的建模精度相对较好。在拔节期和抽穗期, RF 所建立的冠层氮含量 (拔节期 R^2 为 0.80, R_{MSE} 为 0.16%; 抽穗期 R^2 为 0.76, R_{MSE} 为 0.13%) 和地上部氮累积量 (拔节期 R^2 为 0.87, R_{MSE} 为 $9.05 \text{ kg}/\text{hm}^2$; 抽穗期 R^2 为 0.87, R_{MSE} 为 $16.44 \text{ kg}/\text{hm}^2$) 模型测试集精度优于 PLSR 和 BPNN。

表 4 多品种水稻 (云粳 37、极优 6135) 不同生育期 CNC 和 PNA 测试集精度 (均值±标准差)

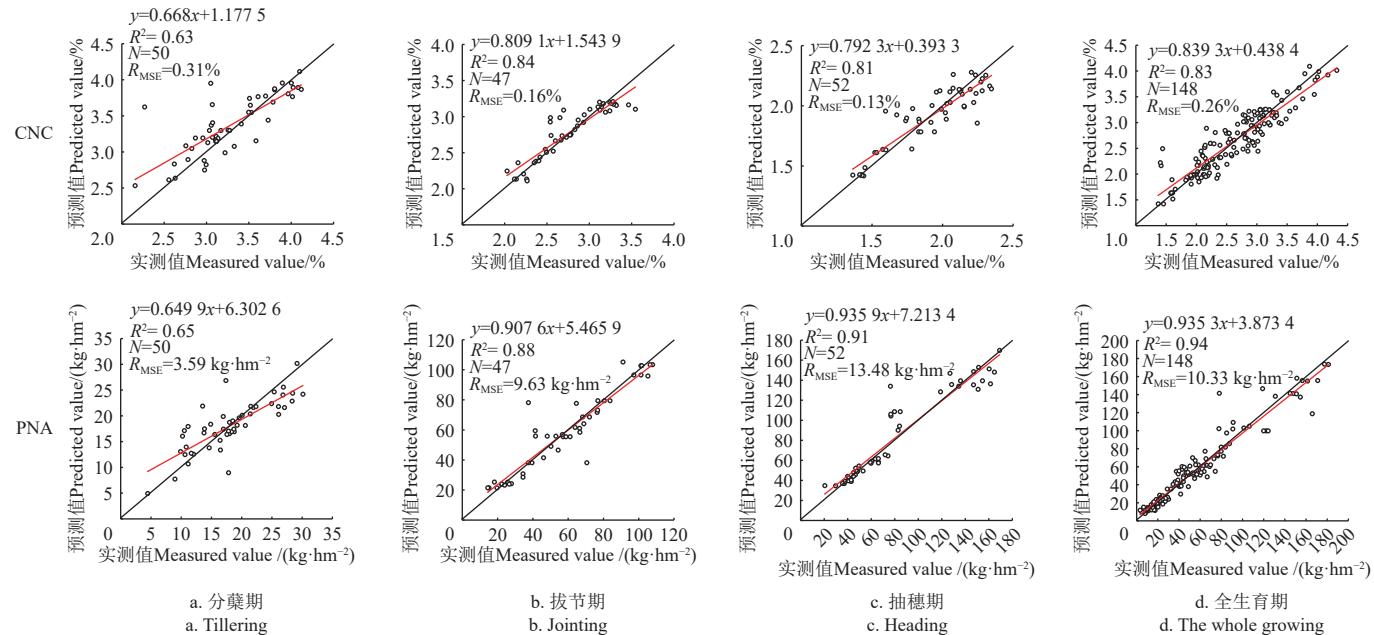
Table 4 Precision (mean ± standard deviation) of CNC and PNA at test sets for multiple varieties of rice (Yunjing 37, Jiyou 6135) at different growth stages

生育期 Growth stage	建模指数 Modeling index	CNC		PNA	
		R^2	$R_{MSE}/\%$	R^2	$R_{MSE}/(\text{kg}/\text{hm}^2)$
分蘖期 Tillering stage	NDVI	NA*	—	0.75	6.82
	NNVI	NA	—	0.71	8.57
	RVI	NA	—	0.75	7.56
	RF	0.57 ± 0.09	0.34 ± 0.03	0.63 ± 0.04	3.76 ± 0.26
	PLSR	0.43 ± 0.05	0.39 ± 0.03	0.64 ± 0.04	6.11 ± 2.08
拔节期 Jointing stage	BPNN	0.46 ± 0.06	0.39 ± 0.03	0.66 ± 0.02	3.54 ± 0.23
	NDVI	NA	—	0.76	26.30
	NNVI	NA	—	NA	—
	RVI	NA	—	0.87	20.50
	RF	0.80 ± 0.04	0.16 ± 0.02	0.87 ± 0.03	9.05 ± 1.32
抽穗期 Heading stage	PLSR	0.72 ± 0.03	0.19 ± 0.01	0.81 ± 0.03	10.57 ± 0.77
	BPNN	0.71 ± 0.03	0.2 ± 0.02	0.82 ± 0.02	10.37 ± 0.74
	NDVI	NA	—	0.78	67.54
	NNVI	NA	—	NA	—
	RVI	NA	—	0.83	50.97
全生育期 The whole growing stage	RF	0.76 ± 0.07	0.13 ± 0.02	0.87 ± 0.06	16.44 ± 4.1
	PLSR	0.75 ± 0.03	0.14 ± 0.01	0.86 ± 0.02	17.75 ± 1.38
	BPNN	0.75 ± 0.02	0.14 ± 0.01	0.86 ± 0.02	17.02 ± 1.4
	NDVI	NA	—	0.78	55.82
	NNVI	NA	—	0.87	73.76
	RVI	NA	—	0.84	33.41
	RF	0.83 ± 0.03	0.28 ± 0.02	0.94 ± 0.02	10.09 ± 1.47
	PLSR	0.21 ± 0.04	0.61 ± 0.02	0.90 ± 0.01	13.20 ± 0.58
	BPNN	0.25 ± 0.03	0.60 ± 0.03	0.90 ± 0.01	12.98 ± 0.82

注: PLSR、RF 和 BPNN 均进行 20 次随机样本组合分析。NA* 指模型 $R^2 < 0.01$ 。
Note: PLSR, RF and BPNN were each applied to 20 different random sample combinations analysis. NA* means the model $R^2 < 0.01$.

在全生育期, 基于RF构建的冠层氮含量监测模型的测试集精度较高, R^2 为0.83, R_{MSE} 为0.28%, 而PLSR和BPNN构建的模型测试集精度较低(R^2 分别为0.21和0.25)、误差较大(R_{MSE} 分别为0.61%和0.60%)。3种建模方法构建的不同试验点、多品种水

稻地上部氮累积量监测模型的测试集精度均较高(R^2 为0.90~0.94, R_{MSE} 为10.09~13.20 kg/hm²), 其中RF构建的模型测试集精度最好。不同试验点、多品种水稻冠层氮含量和地上部氮累积量监测模型测试结果如图4所示。



注: N表示验证集样本数。

Note: N means the number of validation set samples.

图4 不同试验点、多品种水稻冠层氮含量和地上部氮累积量模型预测效果检验

Fig.4 Validation of the prediction effects of the CNC and PNA models for multi-variety rice at different test points

3 讨论

3.1 基于无人机多光谱影像的水稻冠层光谱反射率与氮营养的关系

无人机多光谱影像采集的不同试验点、不同品种水稻各生育期可见光波段反射率随着施氮量的增加而下降, 红边和近红外反射率随着施氮量的增加而增加。这是因为水稻叶片中的叶绿素可以吸收大部分可见光^[20], 叶绿素含量随施氮量增加而增加, 因此可见光波段反射率下降^[21]; 叶绿素含量越高则细胞结构越复杂, 因而红边和近红外波段反射率增加^[22]。本文研究结果表明, 云梗37的光谱反射率在各生育期均大于极优6135, 尤其在近红外区域, 潘庆梅等^[23]的研究结果表明叶片的水分变化导致叶片发生生理变化, 从而引起可见光和近红外波段光谱反射率发生变化; 不同品种的水稻由于叶片结构、基本组成物质含量等有明显差异而形成水分变化, 造成不同品种冠层光谱反射率存在明显差异。

3.2 基于植被指数的单一试验点、单品种水稻氮营养监测

本研究结果表明, 基于掩膜覆盖后NDVI所构建的水稻分蘖期氮营养监测模型精度较好, R^2 超过0.70。这可能是因为分蘖期为水稻生长早期, 覆盖度较低, 无人机多光谱相机采集到的冠层多光谱图像包含大量混合像元, 通过图像掩膜处理能去除水和土壤背景对光谱的影响, 进一步提高氮营养反演模型精度^[24]。于丰华等^[25]

的研究表明, 混合像元的反射率与水稻的反射率在近红外波段范围内有明显差异, 因此很大程度地影响了水稻分蘖期的模型精度。ZHENG等^[26]研究表明, 将植被指数和纹理特征结合作为输入参数建模, 可以在一定程度上提升水稻分蘖期氮营养监测模型的精度。基于植被指数建立的水稻拔节期氮营养监测模型的精度均较高, 其中基于NNVI构建的水稻氮营养监测模型精度最好, R^2 为0.74~0.88。这可能是因为NDVI在水稻拔节期植被覆盖度较高的情况下易出现过饱和^[27], BADGLEY等^[16]研究结果表明, 在高植被覆盖度的情况下利用NNVI(NIRv)可以有效分离出由植被引起的反射率比例, 从而降低过饱和现象并提高建模精度。在抽穗期, 基于NDVI构建的云梗37氮营养监测模型的 R^2 最高, 而基于NNVI构建的极优6135氮营养监测模型的 R^2 最高。这是因为云梗37冠层氮含量降幅较小, 生物量增幅小, 而极优6135冠层氮含量降幅较大, 生物量增幅大, 氮营养往穗部的转移量较大(表4), 因此极优6135的植被冠层较厚、生物量大, 基于NNVI构建的抽穗期氮营养监测模型精度高于NDVI。在3个关键生育期中, 单一品种水稻氮营养监测模型迁移测试的 R_{MSE} 均较大。沈掌泉等^[28]的研究表明, 不同水稻品种间光谱存在差异并且在不同生育期的差异程度不一样, 抽穗期品种间光谱差异最大, 其次是孕穗期, 而分蘖期各品种间差异不明显。杨长明等^[29]的研究结果表明, 不同作物品种对太阳

辐射的吸收具有选择性, 不同试验点的辐照、栽培时间不一致, 可能会进一步加大多光谱反射率对氮营养响应的差异, 因而不同试验点水稻氮营养监测模型的迁移能力不同。本研究结果表明, 基于植被指数无法建立单一水稻品种全生育期冠层氮含量监测模型, 但可以建立地上部氮累积量监测模型。这可能是因为在水稻整个生育期, 冠层氮含量随生育期不断降低, 冠层光谱特征也随之发生变化。在全生育期样本建模时, 氮含量较低的生育期样本会偏离模拟曲线, 氮含量监测模型精度较低, 氮累积量监测模型精度较高, 而本文采用的植被指数无法减小冠层光谱与氮含量之间的不协调性^[30]。薛利红等^[31]和李艳大等^[32]的研究表明, 水稻的氮累积量对冠层的光谱响应比冠层氮浓度更灵敏, 能削弱叶面积指数、叶片内部结构以及内含物等造成的影响, 并且植株氮累积量不仅反映植株个体的氮营养而且反应群体植株的氮营养, 因此, 对植株群体的氮营养状态的监测更有意义。本研究的结果表明, 基于 RVI 的地上部氮累积量监测模型对 2 个品种均有较好的精度和迁移能力, 这可能是因为 RVI 算法可以扩展地物特别是同化不同植被间的光谱差异, 从而在一定程度上提高不同地物反演模型精度和准确性^[33]。

3.3 不同建模方法对不同试验点、多品种水稻氮营养监测建模精度的影响

本研究结果表明, 基于植被指数的单一试验点、单一品种水稻氮营养监测模型的建模方法可以通用, 然而无法利用植被指数分别对不同试验点、多品种水稻冠层氮含量进行建模, 虽然可以建立地上部氮累积监测模型, 但均存在较大误差, 这可能是由于品种间的差异较大, 不同品种水稻冠层氮含量与植被指数之间的关系为非线性, 而植被指数建立的为线性回归模型^[34-35]。前人开发利用 PLSR、RF、BPNN 构建多生育期多品种作物氮营养监测模型, 这主要因为 PLSR、RF、BPNN 能够解析非线性数据之间的联系。PLSR 是一种线性非参数回归方法, 更适于解决共线性的回归分析(自变量多且共线性强)^[36], 本研究自变量是多光谱数据, 输入自变量较少, 模型精度小于 RF 和 BPNN。BPNN 是一种有监督学习多层次前馈神经网络, 能根据预测误差调整网格权值和阈值, 从而准确提取数据特征进行回归训练^[37-38]。本文中利用 RF 建立的不同试验点、多品种水稻冠层氮含量和地上部氮累积量监测模型均有较好的精度和较低的 R_{MSE} , R^2 分别为 0.76~0.83 和 0.87~0.94, R_{MSE} 分别为 0.16%~0.28% 和 9.05~16.44 kg/hm², 基于 RF 构建的多品种水稻全生育期冠层氮含量监测模型精度较高, R^2 为 0.83, 高于 PLSR 和 BPNN, 这与郭燕等^[39]对小麦冠层氮含量监测模型的研究结果相似, 这是因为集成学习算法是一种包含多个决策树的分类器回归方法, 根据决策树节点选取特定的输入变量进行分割, 可确保选取特征为最优特征变量, 增加了模型的泛化能力和优化学习能力。

3.4 利用无人机多光谱影像对作物氮营养监测的优势

消费级无人机多光谱影像设备应用农业, 需要考虑应用场景和成本。无人机成像设备主要是无人机搭载数码相机(RGB), 操作简单、价格便宜, 分辨率高, 在小麦、玉米和水稻氮营养诊断上有一定推广和应用^[40-42]。然而, 无人机 RGB 影像由于辐射定标困难^[43], 加上与作物氮营养相关的敏感波段极有可能不仅仅在 RGB 范围内^[44], 导致作物氮营养诊断效果不稳定。本研究采用的大疆精灵 4 多光谱无人机(自带多光谱相机)整套系统价格约 45 000 元, 拥有 5 个多光谱波段, 并且自带 NDVI 等实时光谱图像, 能够满足分蘖期、拔节期和抽穗期这 3 个施肥关键期的氮营养监测。此外, 配套预处理软件大疆智图能快速进行正射拼接以及辐射校正, 使图像处理更加简单^[45]。本研究利用大疆精灵 4 多光谱无人机采集不同试验点、多品种水稻冠层光谱图像, 利用植被指数、化学计量法和机器学习等方法构建的水稻氮营养监测模型, 能在一定程度上解决不同生态点、多品种水稻氮营养监测模型, 对于大区域尺度、不同品种作物营养诊断与精确施肥有重要意义^[46]。

4 结 论

本研究利用消费级无人机多光谱影像采集水稻冠层光谱反射率, 通过不同建模方法, 探究不同生态点、不同品种水稻氮营养监测模型的精度和普适性, 主要结论如下:

1) 利用植被指数构建分蘖期、拔节期、抽穗期单一试验点、单品种水稻氮营养监测模型, 模型验证集的决定系数 R^2 为 0.53~0.88, 植被指数无法构建水稻全生育期冠层氮含量监测模型, 利用 PLSR (partial least squares regression)、BPNN (back-propagation neural network) 和 RF (random forest) 建立的全生育期冠层氮含量监测模型验证集的 R^2 为 0.61~0.91; 植被指数、PLSR、BPNN 和 RF 构建单一试验点、单品种全生育期地上部氮累积量监测模型验证集的 R^2 为 0.48~0.94, 模型迁移能力均较差。

2) 分别利用植被指数、PLSR、BPNN 和 RF 构建水稻多品种全生育期冠层氮含量和地上部氮累积量监测模型, RF 模型精度最高, R^2 为 0.57~0.94, 优于 PLSR 和 BPNN。

[参 考 文 献]

- [1] 张晓果, 王丹英, 计成林, 等. 水稻氮素吸收利用研究进展[J]. 中国稻米, 2015, 21(5): 13-19.
ZHANG Xiaoguo, WANG Danying, JI Chenglin, et al. Nitrogen absorption and utilization on rice[J]. Chinese Rice, 2015, 21(5): 13-19. (in Chinese with English abstract)
- [2] 杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 遥感学报, 2016, 20(2): 236-256.
DU Peijun, XIA Junshi, XUE Zhaohui, et al. Review of hyperspectral remote sensing image classification[J]. National

- Remote Sensing Bulletin, 2016, 20(2): 236-256. (in Chinese with English abstract)
- [3] 李卫国, 李花, 黄义德. HJ 卫星遥感在水稻长势分级监测中的应用 [J]. 江苏农业学报, 2010, 26(6): 1206-1209.
LI Weiguo, LI Hua, HUANG Yide. Application of HJ satellite remote sensing data in rice growth condition monitoring [J]. Jiangsu Journal of Agricultural Sciences, 2010, 26(6): 1206-1209. (in Chinese with English abstract)
- [4] 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.
LIU Zhong, WAN Wei, HUANG Jinyu, et al. Progress on key parameters inversion of crop growth based on unmanned aerial remote sensing [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(24): 60-71. (in Chinese with English abstract)
- [5] 汪沛, 罗锡文, 周志艳, 等. 基于微小型无人机的遥感信息获取关键技术综述 [J]. 农业工程学报, 2014, 30(18): 1-12.
WANG Pei, LUO Xiwen, ZHOU Zhiyan, et al. Key technology for remote sensing information acquisition based on micro UAV [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2014, 30(18): 1-12. (in Chinese with English abstract)
- [6] 李旭青, 刘湘南, 刘美玲, 等. 水稻冠层氮素含量光谱反演的随机森林算法及区域应用 [J]. 遥感学报, 2014, 18(4): 923-945.
LI Xunqing, LIU Xiangnan, LIU Meiling, et al. Random forest algorithm and regional of spectral inversion model for estimating canopy nitrogen concentration in rice [J]. National Remote Sensing Bulletin, 2014, 18(4): 923-945. (in Chinese with English abstract)
- [7] 于丰华, 邢思敏, 郭忠辉, 等. 基于特征转移植被指数的水稻叶片氮素含量定量估算 [J]. 农业工程学报, 2022, 38(2): 175-182.
YU Fenghua, XING Simin, GUO Zhonghui, et al. Remote sensing inversion of the nitrogen content in rice leaves using character transfer vegetation index [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(2): 175-182. (in Chinese with English abstract)
- [8] 牛亚晓, 张立元, 韩文霆, 等. 基于无人机遥感与植被指数的冬小麦覆盖度提取方法 [J]. 农业机械学报, 2018, 49(4): 212-221.
NIU Yaxiao, ZHANG Liyuan, HAN Wenting, et al. Fractional vegetation cover extraction method of winter wheat based on UAV remote sensing and vegetation index [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4): 212-221. (in Chinese with English abstract)
- [9] 高林, 杨贵军, 王宝山, 等. 基于无人机遥感影像的大豆叶面积指数反演研究 [J]. 中国生态农业学报, 2015, 23(7): 868-876.
GAO Lin, YANG Guijun, WANG Baoshan, et al. Soybean leaf area index retrieval with UAV(unmanned aerial vehicle) remote sensing imagery [J]. Chinese Journal of Eco-Agriculture, 2015, 23(7): 868-876. (in Chinese with English abstract)
- [10] 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.
ZHU Wanxue, LI Shiji, ZHANG Xubo, et al. Estimation of winter wheat yield using optimal vegetation indices from unmanned aerial vehicle remote sensing [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(11): 78-86. (in Chinese with English abstract)
- [11] 王玉娜, 李粉玲, 王伟东, 等. 基于无人机高光谱的冬小麦氮素营养监测 [J]. 农业工程学报, 2020, 36(22): 31-39.
WANG Yuna, LI Fenling, WANG Weidong, et al. Monitoring of winter nitrogen nutrition based on una hyperspectral images [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(22): 31-39. (in Chinese with English abstract)
- [12] 冯帅, 许童羽, 于丰华, 等. 基于无人机高光谱遥感的东北粳稻冠层叶片氮素含量反演方法研究 [J]. 光谱学与光谱分析, 2019, 39(10): 3281-3287.
FENG Shuai, XU Tongyu, YU Fenghua, et al. Research of Method for inversion nitrogen content in canopy leaves of japonica rice in northeastern china based on hyperspectral remote sensing of unmanned aerial vehicle [J]. Spectroscopy and Spectral Analysis, 2019 Personality 39(10): 3281-3287. (in Chinese with English abstract)
- [13] 魏鹏飞, 徐新刚, 李中元, 等. 基于无人机多光谱影像的夏玉米叶片氮含量遥感估测 [J]. 农业工程学报, 2019, 35(8): 126-133.
WEI Pengfei, XU Xingang, LI Zhongyuan, et al. Remote sensing estimation of nitrogen content in summer maize leaves based on multispectral images of UAV [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(8): 126-133. (in Chinese with English abstract)
- [14] WANG L, Chen S S, Li D, et al. Estimation of paddy rice nitrogen content and accumulation both at leaf and plant levels from UAV hyperspectral imagery [J]. *Remote Sensing*, 2021, 13(15): 2956-2977.
- [15] 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.
- [16] BADGLEY G, Field C B, Berry J A. Canopy near-infrared

- reflectance and terrestrial photosynthesis[J]. *Science Advances*, 2017, 3(3): e1602244.
- [17] BLACKMER T M, Schepers J S, Varvel G E. Light reflectance compared with other nitrogen stress measurements in corn leaves[J]. *Agronomy Journal*, 1994, 86(6): 934-938.
- [18] 冯海宽, 陶惠林, 赵钰, 等. 利用无人机高光谱估算冬小麦叶绿素含量[J]. 光谱学与光谱分析, 2022, 42(11): 3575-3580.
- FENG Haikuan, TAO Huilin, ZHAO Yu, et al. Estimation of chlorophyll content in winter wheat based on UAV hyper spectral[J]. *Spectroscopy and Spectral Analysis*, 2022, 42(11): 3575-3580. (in Chinese with English abstract)
- [19] 冯子恒, 宋莉, 张少华, 等. 基于无人机多光谱和热红外影像信息融合的小麦白粉病监测[J]. 中国农业科学, 2022, 55(5): 890-906.
- FENG Ziheng, SONG Li, ZHANG Shaohua, et al. Wheat powdery mildew monitoring based on information fusion of multi-spectral and thermal infrared images acquired with an unmanned aerial vehicle[J]. *Scientia Agricultura Sinica*, 2022, 55(5): 890-906. (in Chinese with English abstract)
- [20] 闫成川, 曲延英, 陈全家, 等. 基于无人机多光谱影像的棉花 SPAD 值及叶片含水量估测[J]. 农业工程学报, 2023, 39(2): 61-67.
- YAN Chengchuan, QU Yanying, CHEN Quanjia, et al. Estimation of cotton SPAD value and leaf water content based on UAV multispectral images[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(2): 61-67. (in Chinese with English abstract)
- [21] 王志君, 李红宇, 夏玉莹, 等. 采用叶片光谱反射率预测寒地水稻稻米蛋白质含量[J]. 农业工程学报, 2022, 38(21): 147-158.
- WANG Zhijun, LI Hongyu, XIA Yuying, et al. Prediction of rice protein content in cold region based on leaf spectral reflectance[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(21): 147-158. (in Chinese with English abstract)
- [22] 周敏姑, 邵国敏, 张立元, 等. 无人机多光谱遥感反演冬小麦 SPAD 值[J]. 农业工程学报, 2020, 36(20): 125-133.
- ZHOU Mingu, SHAO Guomin, ZHANG Liyuan, et al. Inversion of SPAD value of winter wheat by multispectral remote sensing of unmanned aerial vehicles[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2020, 36(20): 125-133. (in Chinese with English abstract)
- [23] 潘庆梅, 张劲松, 张俊佩, 等. 不同品种核桃叶片含水量与高光谱反射率的相关性差异分析[J]. 林业科学研究, 2019, 32(6): 1-6.
- PAN Qingmei, ZHANG Jinsong, ZHANG Junpei, et al. Analysis of correlation and differences between leaf moisture and hyperspectral reflectance among different walnut varieties[J]. *Forest Research*, 2019, 32(6): 1-6. (in Chinese with English abstract)
- [24] CHU X, GUO Y J, HE J Y, et al. Comparison of different hyperspectral vegetation indices for canopy leaf nitrogen concentration estimation in rice[J]. *Plant and Soil*, 2014, 376(1-2): 193-209.
- [25] 于丰华, 曹英丽, 许童羽, 等. 基于高光谱遥感处方图的寒地分蘖期水稻无人机精准施肥[J]. 农业工程学报, 2020, 36(15): 103-110.
- YU Fenghua, CAO Yingli, XU Tongyu, et al. Precision fertilization by UAV for rice at tillering stage in cold region based on hyperspectral remote sensing prescription map[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2020, 36(15): 103-110. (in Chinese with English abstract)
- [26] ZHENG H B, CHENG T, LI D, et al. Combining unmanned aerial vehicle (UAV)-based multispectral imagery and ground-based hyperspectral data for plant nitrogen concentration estimation in rice[J]. *Frontiers in Plant Science*, 2018, 9: 936.
- [27] 王薇. 基于高光谱的稻麦氮素营养监测研究 [D]. 南京: 南京农业大学, 2011.
- WANG Wei. Monitoring Nitrogen Nutrition with Hyperspectral Remote Sensing in Rice and Wheat[D]. Nanjing: Nanjing Agricultural University, 2011.
- [28] 沈掌泉, 王人潮, 王珂. 不同早稻品种的光谱特性及其与农学参数的相关性[J]. 浙江农业大学学报, 1993(S1): 32-37.
- SHEN Zhangquan, WANG Renchao, WANG Ke. Reflective spectral characteristics of different early rice cultivars and the relationship of agronomic variables and vegetation index[J]. *Journal of Zhejiang University (Agriculture and Life Sciences)*, 1993(S1): 32-37. (in Chinese with English abstract)
- [29] 杨长明, 杨林章, 韦朝领, 等. 不同品种水稻群体冠层光谱特征比较研究[J]. 应用生态学报, 2002, 13(6): 689-692.
- YANG Changming, YANG Linzhang, WEI Chaoling, et al. Canopy spectral characteristics of different rice varieties[J]. *Chinese Journal of Applied Ecology*, 2002, 13(6): 689-692. (in Chinese with English abstract)
- [30] 冯伟, 姚霞, 朱艳, 等. 基于高光谱遥感的小麦叶片含氮量监测模型研究[J]. 麦类作物学报, 2008, 163(5): 851-860.
- FENG Wei, YAO Xia, ZHU Yan, et al. Monitoring leaf nitrogen concentration by hyperspectral remote sensing in wheat[J]. *Journal of Triticeae Crops*, 2008, 163(5): 851-860. (in Chinese with English abstract)
- [31] 薛利红, 曹卫星, 罗卫红, 等. 基于冠层反射光谱的水稻群体叶片氮素状况监测[J]. 中国农业科学, 2003, 36(7):

- 807-812.
- XUE Lihong, CAO Weixing, LUO Weihong, et al. Diagnosis of nitrogen status in rice leaves with the canopy spectral reflectance[J]. *Scientia Agricultura Sinica*, 2003, 36(7): 807-812. (in Chinese with English abstract)
- [32] 李艳大, 叶春, 曹中盛, 等. 基于作物生长监测诊断仪的双季稻叶片氮含量和氮积累量监测[J]. 应用生态学报, 2020, 31(9): 3040-3050.
- LI Yanda, YE Chun, CAO Zhongsheng, et al. Monitoring leaf nitrogen concentration and nitrogen accumulation of double cropping rice based on crop growth monitoring and diagnosis apparatus[J]. *Chinese Journal of Applied Ecology*, 2020, 31(9): 3040-3050. (in Chinese with English abstract)
- [33] 周冬琴, 朱艳, 田永超, 等. 以冠层反射光谱监测水稻叶片氮积累量的研究[J]. 作物学报, 2006, 32(9): 1316-1322.
- ZHOU Dongqin, ZHU Yan, TIAN Yongchao, et al. Monitoring leaf nitrogen accumulation with by canopy spectral reflectance in rice[J]. *Acta Agronomica Sinica*, 2006, 32(9): 1316-1322. (in Chinese with English abstract)
- [34] 田庆久, 阎祥军. 植被指数研究进展[J]. 地球科学进展, 1998, 13(4): 10-16.
- TIAN Qingjiu, MIN Xiangjun. Advances in study on vegetation indices[J]. *Advances in Earth Science*, 1998, 13(4): 10-16. (in Chinese with English abstract)
- [35] 张雷, 王琳琳, 张旭东, 等. 随机森林算法基本思想及其在生态学中的应用—以云南松分布模拟为例[J]. 生态学报, 2014, 34(3): 650-659.
- ZHANG Lei, WANG Linlin, ZHANG Xudong, et al. The basic principle of random forest algorithm and its applications in ecology -A case study of pinus yunnanensis[J]. *Acta Ecologica Sinica*, 2014, 34(3): 650-659. (in Chinese with English abstract)
- [36] BERGER K, KATJA V, JOCHEN F, et al. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions[J]. *Remote Sensing of Environment*, 2020, 242: 111758.
- [37] 方匡南, 吴见彬, 朱建平, 等. 随机森林方法研究综述[J]. 统计与信息论坛, 2011, 26(3): 32-38.
- FANG Kuangnan, WU Jianbing, ZHU Jianping, et al. A review of technologies on random forests[J]. *Journal of Statistics and Information*, 2011, 26(3): 32-38. (in Chinese with English abstract)
- [38] 李欣海. 随机森林模型在分类与回归分析中的应用[J]. 应用昆虫学报, 2013, 50(4): 1190-1197.
- LI Xinhai. Using “random forest” for classification and regression[J]. *Chinese Journal of Applied Entomology*, 2013, 50(4): 1190-1197. (in Chinese with English abstract)
- [39] 郭燕, 井宇航, 王来刚, 等. 基于无人机影像特征的冬小麦植株氮含量预测及模型迁移能力分析[J]. 中国农业科学, 2023, 56(5): 850-865.
- GUO Yan, JING Yuhang, WANG Laigang, et al. UVA multispectral image-based nitrogen content prediction and the transferability analysis of models in winter wheat plant[J]. *Scientia Agricultura Sinica*, 2023, 56(5): 850-865. (in Chinese with English abstract)
- [40] 李红军, 李佳珍, 雷玉平, 等. 无人机搭载数码相机航拍进行小麦、玉米氮素营养诊断研究[J]. 中国生态农业学报, 2017, 25(12): 1832-1841.
- LI Hongjun, LI Jiazen, LEI Yuping, et al. Diagnosis of nitrogen nutrition of winter wheat and summer corn using images from digital camera equipped on unmanned aerial vehicle[J]. *Chinese Journal of Eco-Agriculture*, 2017, 25(12): 1832-1841. (in Chinese with English abstract)
- [41] 江杰, 张泽宇, 曹强, 等. 基于消费级无人机搭载数码相机监测小麦长势状况研究[J]. 南京农业大学学报, 2019, 42(4): 622-631.
- JIANG Jie, ZHANG Zeyu, CAO Qiang, et al. Use of a digital camera mounted on a consumer-grade unmanned aerial vehicle to monitor the growth status of wheat[J]. *Journal of Nanjing Agricultural University*, 2019, 42(4): 622-631. (in Chinese with English abstract)
- [42] QIU Z C, MA F, LI Z W, et al. Estimation of nitrogen nutrition index in rice from UAV RGB images coupled with machine learning algorithms[J]. *Computers and Electronics in Agriculture*, 2021, 189: 106421.
- [43] 高林, 杨贵军, 李红军, 等. 基于无人机数码影像的冬小麦叶面积指数探测研究[J]. 中国生态农业学报, 2016, 24(9): 1254-1264.
- GAO Lin, YANG Guijun, LI Hongjun, et al. Winter wheat LAI estimation using unmanned aerial vehicle RGB-imaging[J]. *Chinese Journal of Eco-Agriculture*, 2016, 24(9): 1254-1264. (in Chinese with English abstract)
- [44] 王嘉盼, 武红旗, 王德俊, 等. 基于无人机可见光影像与生理指标的小麦估产模型研究[J]. 麦类作物学报, 2021, 41(10): 1307-1315.
- WANG Jiapan, WU Hongqi, WANG Dejun, et al. Research on wheat yield estimation model based on UAV visible light image and physiological index[J]. *Journal of Triticeae Crops*, 2021, 41(10): 1307-1315. (in Chinese with English abstract)
- [45] 精灵 4 多光谱版 - 技术参数 - DJI 大疆创新 [EB/OL]. 2020-07-17[2022-07-25].<https://www.dji.com/cn/p4-multispectral/specs>.
- [46] 班松涛. 水稻长势无人机遥感监测研究 [D]. 杨凌: 西北农林科技大学, 2020.
- BAN Songtao. Monitoring Rice Growth Conditions Using UAV Remote Sensing System[D]. Yangling: Northwest A&F University, 2020.

Rice nitrogen nutrition monitoring based on unmanned aerial vehicle multispectral image

LING Qihan¹, KONG Faming^{1,2}, NING Qiang^{1,2}, WEI Yong^{1,2}, LIU Zhan³, DAI Mingzhu³, ZHOU Yu³,
ZHANG Yueqiang^{1,2,4}, SHI Xiaojun^{1,2,4}, WANG Jie^{1,2,4}✉

(1. College of Resources and Environment, Southwest University, Chongqing 400716, China; 2. Interdisciplinary Research Center for Agricultural Green Development in Yangtze River Basin, Chongqing 400716, China; 3. Menghai Manxiang Yuntian Agricultural Development Co., LTD., Menghai 666205, China; 4. National Monitoring Station of Soil Fertility and Fertilizer Efficiency on Purple Soils, Chongqing 400716, China)

Abstract: An accurate and universal monitoring model of nitrogen nutrition can greatly contribute to the precise management and application of regional rice. In this study, a systematic investigation was carried out to explore the impact of the images on the monitoring models. The consumer-grade multispectral images were captured by unmanned aerial vehicles (UAV) from the different ecological sites and rice varieties. A series of field experiments were conducted at two test sites: Mengzhe Town, Xishuangbanna, Yunnan Province (with trial variety Yunjing 37) and Beibei District, Chongqing City (with trial variety Jiyu 6135) in South China, with the varying nitrogen levels. Four multispectral drones (DJI Phantom) were used to capture the multispectral images of the rice canopy during tillering, jointing, and heading stages. The nitrogen content in rice plant canopies (CNC) was measured to calculate the above-ground nitrogen accumulation (PNA) using the Kjeldahl method. The nitrogen nutrition monitoring models were established using vegetation indices, partial least-squares regression (PLSR), random forest (RF), and backpropagation neural network (BPNN) for the single trial site, single variety, different trial sites, and multiple varieties of rice. The transferability was also explored in the models. The monitoring models were established for the CNC and PNA during each growth stage of rice for the single trial site and single variety with the high accuracy (normalized difference vegetation index NDVI or near-infrared normalized vegetation index NNVI, where the coefficient of determination was 0.68–0.88). However, the inaccurate model was obtained with the vegetation index during the tillering stage (NDVI, the coefficient of determination was 0.53–0.79), indicating the low transferability of all models. It was difficult for the vegetation indices to construct the monitoring models for the canopy nitrogen content throughout the entire growth period of rice. But a monitoring model was established for the above-ground nitrogen accumulation of single-variety rice in the period of the growth using the ratio vegetation index, the high accuracy and the high transferability of the model. The monitoring models constructed by PLSR, RF, and BPNN were more accurate than those by vegetation indices. Among them, the highest accuracy was achieved in the monitoring model for the canopy nitrogen content and above-ground nitrogen accumulation in the entire growth period of multiple varieties using RF, with the coefficient of determination values were 0.84 and 0.94, respectively, and root-mean-square errors of 0.28% and 10.09 kg/hm², respectively. The finding can provide a theoretical basis and technical support for the application of consumer-grade multispectral images captured by drones in monitoring rice nitrogen nutrition during the entire growth period of different ecological sites and rice varieties.

Keywords: UAV; vegetation index; machine learning; multi-spectral imaging; nitrogen nutrition monitoring; rice