

基于无人机高光谱遥感的水稻氮营养诊断方法

许童羽^{1,2} 白驹驰¹ 郭忠辉¹ 金忠煜¹ 于丰华^{1,2}

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866; 2. 辽宁省农业信息化工程技术研究中心, 沈阳 110866)

摘要: 氮亏缺量能够直接反映作物氮营养缺失程度,快速、大面积获取水稻氮亏缺量信息对实现水稻精准施肥具有重要意义。而现有的研究大都集中于利用无人机遥感监测水稻氮营养情况,对氮亏缺量本身的研究较少。本研究基于无人机高光谱遥感获取冠层光谱数据、通过田间采样获取水稻农学数据,研究东北地区水稻临界氮浓度曲线构建方法,在此基础上确定水稻氮亏缺量;以氮亏缺量约等于0状态下光谱为标准光谱,分别对光谱反射率进行比值、差值、归一化差值变换,通过竞争性自适应重加权采样法对原始光谱反射率与变换后光谱反射率进行特征波长提取,并以二者提取的特征波长为输入变量,氮亏缺量为输出变量,分别构建基于多元线性回归、极限学习机与蝙蝠算法优化极限学习机3种算法的水稻氮亏缺量反演模型。结果表明:基于田间数据构建东北地区水稻临界氮浓度曲线方程系数 a 、 b 分别为2.026与-0.4603,和以往研究基本一致;相比其余变换方法,对水稻冠层光谱进行归一化差值变换与特征波长提取显著提高了冠层光谱反射率与水稻氮亏缺量的相关性,也提高了后续反演模型的反演结果;以归一化差值光谱为输入的蝙蝠算法优化极限学习机反演模型预测效果显著优于其余模型,验证集 R^2 为0.8306, RMSE为0.8141 kg/hm²,具有较好的氮亏缺量估测效果。

关键词: 水稻; 无人机遥感; 高光谱; 氮亏缺量; 蝙蝠算法优化; 极限学习机

中图分类号: S252

文献标识码: A

文章编号: 1000-1298(2023)02-0189-09

OSID:



Diagnosis Method of Rice Nitrogen Deficiency Based on UAV Hyperspectral Remote Sensing

XU Tongyu^{1,2} BAI Juchi¹ GUO Zhonghui¹ JIN Zhongyu¹ YU Fenghua^{1,2}

(1. School of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. Liaoning Agricultural Informatization Engineering Technology Research Center, Shenyang 110866, China)

Abstract: Nitrogen (N) deficiency can directly reflect the degree of crop N nutrient deficiency, and it is important to obtain the information of rice N deficiency quickly and in a large area to achieve accurate fertilization of rice. Most of the existing studies focused on the use of UAV remote sensing to monitor rice N nutrition, and less research was conducted on N deficiency itself. Based on the canopy spectral data obtained by UAV hyperspectral remote sensing and rice agronomic data obtained by field sampling, the method of constructing the critical nitrogen concentration curve of northeastern rice was studied, and the nitrogen deficit of rice on this basis was determined; the spectrum in the state of nitrogen deficit approximately equal to 0 was used as the standard spectrum, and ratio, difference and normalized difference transformations on the spectral reflectance data were carried out respectively, and then the competitive adaptive re-weighting sampling method was used to the inversion models of rice nitrogen deficit based on the multivariable linear regression (MLR), extreme learning machine (ELM) and the bat algorithm optimized extreme learning machine (BA-ELM) were constructed by taking the extracted feature bands as input variables and the nitrogen deficit as output variables. The results showed that the equation coefficients a and b of the critical nitrogen concentration curve of northeastern rice were 2.026 and -0.4603, respectively, based on field data, which were consistent with previous studies; compared with other transformation methods, the normalized difference transformation and feature band extraction of the rice canopy spectrum significantly improved the correlation between the canopy spectral reflectance and rice nitrogen deficit, and also improved the inversion of the subsequent inversion model. The BA-

收稿日期: 2022-03-04 修回日期: 2022-05-20

基金项目: 辽宁省教育厅重点攻关项目(LSNZD202005)

作者简介: 许童羽(1967—),男,教授,博士生导师,主要从事精准农业和智慧农业相关研究,E-mail: xutongyu@syau.edu.cn

ELM inversion model with normalized difference spectra as input predicted significantly better than the rest of the models, with the validation set R^2 of 0.830 6, RMSE of 0.814 1 kg/hm², which had better estimation of N deficit.

Key words: rice; UAV remote sensing; hyperspectral; nitrogen deficit; bat algorithm optimization; extreme learning machine

0 引言

氮素是对作物生长、发育,以及最终产量影响最明显的元素,其含量变化会对光合作用、蛋白质合成以及碳氮代谢产生影响。氮素的缺乏会抑制作物地上部分和根系的生长,限制繁殖器官的形成和发育,并显著影响作物最终产量以及品质^[1-2]。因此,快速、精准、大面积地对水稻田间氮素需求情况进行诊断,并依据诊断结果实现精准施肥,是实现水稻田间精准管理和保证水稻产量的重要手段。传统的水稻氮营养诊断标准主要基于临界氮浓度曲线(Critical N concentration curve)。GREENWOOD等^[3]最早提出了临界氮浓度的概念,即作物达到最大生物量所需的最小氮浓度。随后LEMAIRE等^[4]提出了基于临界氮浓度理论的氮营养指数(Nitrogen nutrition index, NNI)。氮营养指数作为作物氮营养诊断的重要指标,能够定量描述作物的氮营养丰缺状况^[5-6],为作物氮亏缺量的确定提供了理论依据。吕茹洁等^[7]基于临界氮浓度理论,计算出超级杂交稻和常规稻的临界氮浓度曲线,并依据曲线确定了二者的氮亏缺量与适宜施肥量,为水稻氮亏缺量的确定提供了理论支撑。

然而,基于氮营养指数计算氮亏缺量需要通过田间采样获取数据,成本较高、测量周期长,且结果具有滞后性^[8],难以对实际农业生产做出指导。近年来,随着高光谱遥感技术的发展,利用无人机高光谱遥感技术获取水稻氮营养状况信息成为精准农业领域的重要发展方向。高光谱遥感技术能够通过分析作物光谱数据来获得其生长信息,具有快速、无损、准确等优点^[9]。对此,国内外已在相关领域取得一定的研究进展^[10-11]。这些研究大多数集中在利用高光谱对水稻氮含量进行反演,而单纯的氮含量信息难以反映水稻的氮营养丰缺状况,因此,结合无人机高光谱遥感技术与临界氮浓度曲线理论,通过光谱反演氮营养指数的形式对水稻进行氮营养诊断成为当前的研究热点^[12-13]。ZHA等^[14]通过无人机遥感获取水稻冠层光谱数据,构建多种植被指数并结合机器学习算法对水稻地上生物量、氮吸收量与氮营养指数进行反演建模,结果显示随机森林算法显著提高了氮营养指数反演精度;QIU等^[15]提取

水稻 RGB 光谱信息并构建植被指数,最后比较多种机器学习方法反演水稻氮营养指数的精度,认为随机森林算法在各生育期表现最佳。

前人研究大都以对水稻进行氮营养诊断为主,而单纯的氮营养诊断只能判断水稻的生长状况,需要进一步获取水稻氮亏缺量数据才能以此对精准施肥做出定量指导。因此,本文拟以水稻无人机高光谱数据与氮亏缺量为研究对象,以水稻各个时期氮亏缺量约等于0的冠层光谱为标准,对水稻高光谱数据进行比值、差值与归一化差值变换,然后利用竞争性自适应重加权采样法处理原始光谱与变换光谱,筛选出效果最佳的光谱特征波段,并建立基于多元线性回归、极限学习机与蝙蝠算法优化极限学习机的水稻氮亏缺量反演模型,最后比较模型反演效果,确定基于高光谱数据的水稻氮亏缺量最佳反演方法,以期快速获取水稻氮亏缺量提供研究方向,也为基于田间水稻氮营养状况的精准施肥提供定量指导。

1 数据获取与反演模型建立

1.1 实验设计

实验于2021年6—9月在辽宁省鞍山市海城市耿庄镇沈阳农业大学精准农业航空科研基地(北纬40°58'45.39",东经122°43'47.01")进行,为避免阴雨多云天气对遥感数据采集造成误差,数据采集过程选择天气晴好的日期,如遇云量超过20%或不利于遥感数据采集天气则顺延采集。水稻品种为北粳1705。实验区域如图1所示,实验田分为2个大区,其中实验区1设立5个氮肥梯度,施氮量分别为N0(0 kg/hm²)、N1(75 kg/hm²)、N2(150 kg/hm²)、N3(225 kg/hm²)、N4(300 kg/hm²),实验区2也设计5个氮肥梯度,施氮量分别为:N0(0 kg/hm²)、N1(50 kg/hm²)、N2(100 kg/hm²)、N3(150 kg/hm²)、N4(200 kg/hm²),氮肥基追比为5:3:2。实验区1对每个梯度设立3个重复小区,共设立3×5=15个小区。每个小区面积为5 m×8 m=40 m²,实验区2每个小区面积为660 m²,除氮肥梯度外两组实验区田间管理一致,磷钾肥施用量采用当地标准施用量进行,其中磷肥标准施用量为144 kg/hm²,钾肥标准施用量为192 kg/hm²,基追比为1:1,其余田间管理

同常规高产管理。田间采样由分蘖期至抽穗期,采样间隔9 d,每次采样在各实验小区选取具有代表性的3穴水稻进行冠层光谱、水稻氮浓度与地上干物质量的获取,最后结果取平均值作为该小区水稻氮浓度与地上干物质量。实验区1共采集小区数据120组,实验区2共采集小区数据88组,共计208组样本。

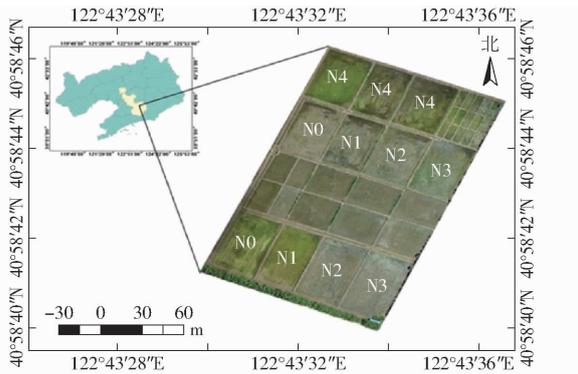


图1 实验小区分布图

Fig. 1 Plot distribution of experimental field

1.2 数据获取

1.2.1 水稻光谱参量获取

无人机高光谱平台采用深圳大疆创新公司M600 PRO型六旋翼无人机,高光谱成像仪选用四川双利合谱公司GaiaSky-mini内置推扫式机载高光谱成像系统,高光谱波段范围为400~1 000 nm,分辨率为3 nm,有效波段数为253个。无人机高光谱遥感平台数据采集时间为选择太阳光强较为稳定的时段11:00—12:00,无人机飞行高度为150 m。运用ENVI 5.3+IDL工具软件对获取的高光谱遥感影像进行小区高光谱数据提取,运用波谱角填图方法去除干扰地物光谱的影响,对每个小区的感兴趣区计算平均光谱,再利用Matlab软件对平均光谱进行重采样处理,使光谱分辨率降为1 nm,最后利用高斯滤波器对重采样后光谱进行去噪处理,结果作为每个实验小区的高光谱信息。

1.2.2 水稻农学参量获取

测定样本氮浓度与地上干物质量时,首先对每个小区的水稻进行破坏性采样,将样本带至实验室,然后将样本放入干燥箱中105℃杀青30 min后,80℃干燥至恒质量;之后测量干燥后样本的干物质量,并根据种植密度换算成地上部干物质量;最后将干燥后的样本磨碎,对研磨后的样本通过凯氏定氮法测量植株氮浓度。

1.3 基于临界氮浓度曲线的氮亏缺量计算方法

临界氮浓度是作物达到最大生物量所需的最小氮浓度,因此以临界氮浓度为基准可以推导出临界氮积累量方程,进而建立氮亏缺量方程,并确定水稻

氮亏缺量^[7]。

根据JUSTES等^[16]提出的临界氮浓度曲线构建方法,以所测水稻氮浓度与地上干物质量为基础构建东北水稻的临界氮浓度曲线,具体方法如下:对比不同氮肥梯度下测定的氮浓度与干物质量,通过方差分析将样本分为受氮营养限制组与不受氮营养限制组;对受氮营养限制组的数据,将地上干物质量与氮浓度进行线性拟合;对不受氮营养限制组,对同一时期样本地上干物质量取平均值代表该时期最大地上干物质量;取各时期拟合曲线于最大地上干物质量中位置的截点为该时期的理论临界氮浓度点;将各时期临界氮浓度点进行幂函数拟合,构建作物临界氮浓度曲线

$$N_c = aM^{-b} \quad (1)$$

式中 N_c ——水稻临界氮质量比, g/g

M ——地上干物质量, t/hm²

a 、 b ——曲线参数

根据临界氮浓度曲线推导出临界氮积累量方程与氮亏缺量方程,推导过程为

$$N_{cna} = 10aM^{1-b} \quad (2)$$

$$N_{and} = N_{cna} - N_{na} \quad (3)$$

式中 N_{cna} ——临界氮浓度条件下植株氮积累量, kg/hm²

N_{and} ——氮亏缺量, kg/hm²

N_{na} ——不同施氮量下植株实际氮积累量, kg/hm²

1.4 光谱数据处理

1.4.1 高光谱数据变换

由于临界氮浓度状态下作物地上部氮营养状况与冠层叶片结构达到最佳状态,而这些都是影响水稻冠层光谱反射率的直接因素^[17-18],因此,相比非临界氮浓度状态下的作物,临界氮浓度下水稻同其余水稻无论在光谱层面还是氮营养状况层面都存在一定的差异。为了在光谱层面突出临界氮浓度下水稻与其余水稻的差距,本研究选取各个时期 $N_{and} \approx 0$ kg/hm²样本对应的光谱反射率,将其与同时期其余样本光谱反射率分别做比值、差值和归一化差值变换,计算方法为

$$R_{sv} = \frac{R_i}{R_{NC}} \times 100\% \quad (4)$$

$$R_D = R_{NC} - R_i \quad (5)$$

$$R_{ND} = \frac{R_{NC} - R_i}{R_{NC} + R_i} \times 100\% \quad (6)$$

式中 R_{sv} ——比值光谱反射率, %

R_D ——差值光谱反射率, %

R_{ND} ——归一化差值光谱反射率, %

R_{NC} ——临界氮浓度状态下样本光谱反射率, %

R_i ——同时期其余光谱反射率, %

1.4.2 高光谱特征波段提取

由于全波段光谱相邻波段数据相似度较高,且存在大量与所求变量无关的冗余信息,基于全波段光谱的建模往往存在运行速度较慢,模型误差较高,反演精度较低等缺点^[19-21]。为了减少输入变量个数,降低数据冗余性,提高建模速度与精度,本文采用竞争性自适应重加权采样法(Competitive adaptive reweighted sampling, CARS)对光谱反射率数据进行特征提取。CARS算法基于达尔文进化论简单有效的生存原则“适者生存”,对不适应的波长变量进行逐步淘汰。首先,利用蒙特卡罗采样法(Monte Carlo simulation, MCS)采样 N 次,再以偏最小二乘回归(Partial least squares regression, PLSR)系数绝对值作为衡量标准,保留回归系数绝对值大的波长变量,去除回归系数绝对值小的波长变量,从而获得一系列的波长变量子集;然后对比每次产生的PLSR模型的交互验证均方差值(Root mean square error of cross validation, RMSECV), RMSECV 最小的那个模型所对应的变量子集被选为最优变量子集。

1.5 反演建模方法

选用多元线性回归(Multivariable linear regression, MLR)、极限学习机(Extreme learning machine, ELM)与蝙蝠算法优化极限学习机(Bat algorithm optimized extreme learning machine, BA-ELM)3种算法进行建模,并通过3种模型对训练集与测试集预测结果的决定系数 R^2 与均方根误差(Root mean square error, RMSE)来判断模型的反演精度与鲁棒性。

多元线性回归是一种解释单因变量与多自变量间线性关系的传统回归建模方法,模型结果唯一,并能够更好地体现各个自变量与因变量间的相关程度。

极限学习机是一种基于单层前馈神经网络理论的改进算法,具有学习速率快、泛化能力强、训练精度较高等优点^[22-23]。但由于极限学习机每次运行中输入层与隐含层之间的连接权值和隐含层神经元的阈值都是随机生成的,其在训练稳定性上存在不足,且容易陷入局部最优解。因此,本研究采用蝙蝠算法对极限学习机隐含层初始权重进行优化。

蝙蝠算法是一种新的元启发式优化算法。该算法模拟自然界中蝙蝠利用回声定位来探测猎物和规避障碍物的原理,控制蝙蝠发出不同频率的搜索脉

冲来寻找最优解。相较于经典的粒子群算法,蝙蝠算法引入了局部搜索机制,在每轮迭代中最优蝙蝠个体会采用随机搜索的方式进行局部寻优,有助于算法跳出局部最优解,增强算法的全局搜索性^[24-26]。

2 结果与分析

2.1 植株氮亏缺量确定

2.1.1 植株氮浓度与地上部干物质质量统计分析

东北水稻全生育期植株氮浓度与地上部干物质质量的基本信息如表1所示,由于实验包含全生育期采样数据,实验区1与实验区2中的植株氮浓度与地上部干物质质量离散程度较高,最大值与最小值差别较大。其中实验区1由于施氮梯度较高,其整体氮浓度与地上部干物质质量高于实验区2。实验区2由于在分蘖期与拔节期采样密度较高,其平均氮浓度较高,平均地上部干物质质量较低。

表1 植株氮浓度与地上部生物量统计

Tab.1 Plant N concentration and above-ground biomass statistic

指标	实验区1植	实验区1地	实验区2植	实验区2地
	株氮质量比/ ($g \cdot g^{-1}$)	上部生物量/ ($t \cdot hm^{-2}$)	株氮质量比/ ($g \cdot g^{-1}$)	上部生物量/ ($t \cdot hm^{-2}$)
最大值	5.18	2.35	5.86	1.38
最小值	1.00	0.10	1.60	0.04
平均值	2.55	0.73	3.82	0.29
标准偏差	1.05	0.55	0.96	0.27

2.1.2 临界氮浓度曲线与氮亏缺量计算

根据1.3节提出的临界氮浓度曲线的构建方法,本文将每个采样日获得的氮浓度与干物质质量进行回归拟合,计算出每个采样日的东北水稻临界氮浓度,之后根据各个临界氮浓度与对应的干物质质量构建东北水稻临界氮浓度曲线(图2)。曲线方程为

$$N_c = 2.026M^{-0.4603} \quad (10)$$

决定系数 R^2 为 0.8747, RMSE 为 0.3825 g/g。

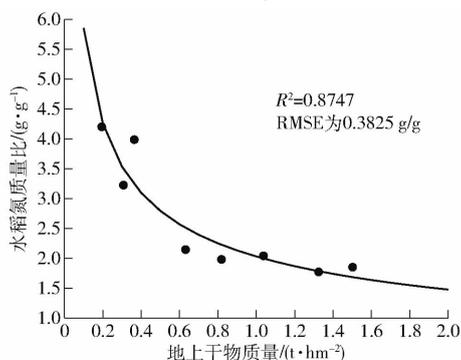


图2 临界氮质量比拟合曲线

Fig.2 Fitting of critical nitrogen concentration

曲线参数 a 、 b 分别为 2.026、-0.460 3, 与 SONG 等^[27] 计算出的东北水稻临界氮浓度曲线参数 $a = 1.99$ 、 $b = -0.44$ 非常接近, 可进一步用于东北水稻的氮亏缺量计算。

根据 1.3 节中的计算方法, 本文结合样本数据与临界氮浓度曲线, 计算各样本的氮亏缺量。各个氮肥梯度的平均氮亏缺量如图 3 所示, 随着氮肥梯度的增高, 氮亏缺量整体呈下降趋势, 综合实验区 1 与实验区 2 氮亏缺量的下降趋势可知, 水稻最佳施肥量在 150 ~ 200 kg/hm² 之间。

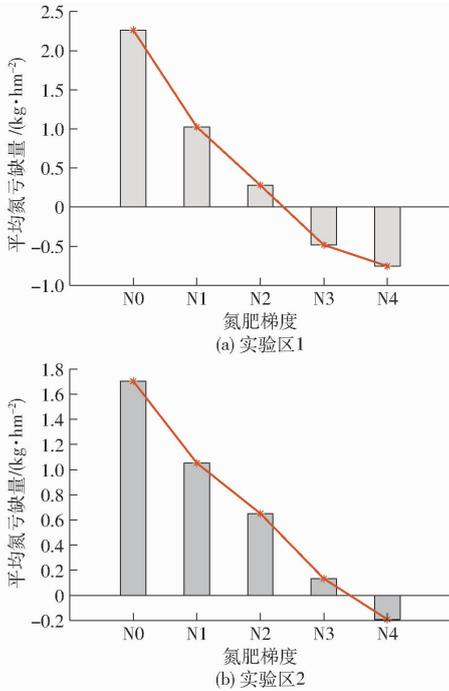


图 3 各氮肥梯度平均氮亏缺量

Fig. 3 Average N deficit of each N fertilizer gradient

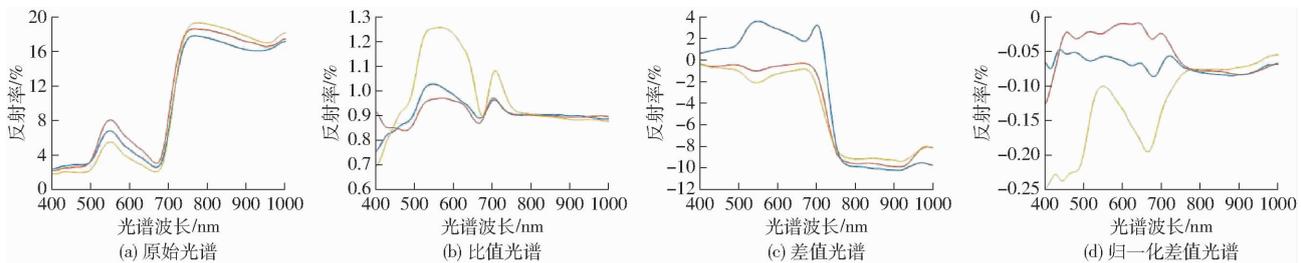


图 4 原始与变换光谱反射率

Fig. 4 Reflectance of original and transformed spectra

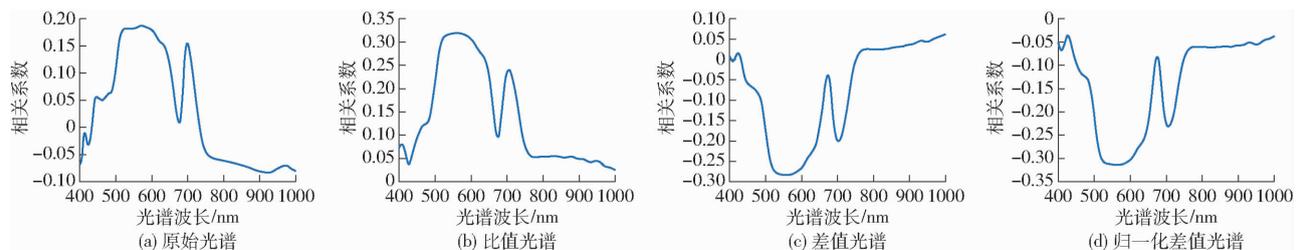


图 5 原始与变换光谱相关性

Fig. 5 Correlation of original and transformed spectra nature

2.2 光谱数据处理

2.2.1 光谱数据变换结果

根据 1.4.1 节提出的方法, 本研究选取各个时期 $N_{and} \approx 0$ kg/hm² 的样本对应光谱反射率, 将其与其余样本光谱反射率分别作比值、差值、归一化差值变换, 变换结果与相关性分析结果如图 4、5 所示, 对比可得, 不同施氮水平下原始光谱全波段反射率变换趋势基本一致, 在可见光波段 (波长 400 ~ 700 nm) 光谱反射率均呈“先升后降”的变化规律。同时, 在绿波段 (波长 550 nm 附近) 出现明显的反射峰, 在红波段 (波长 680 nm 附近) 出现明显的吸收谷。在波长 680 ~ 770 nm 内不同施氮水平的光谱反射率曲线变化基本一致, 反射率急剧升高, 在近红外波段 (770 ~ 1 000 nm) 形成较高的反射平台; 不同施氮水平下比值、差值与归一化差值光谱反射率有一定差别, 但在绿波段与红波段差别较为明显; 在与氮亏缺量的相关性方面, 4 种光谱反射率与氮亏缺量的相关性图像趋势基本一致, 在红波段与绿波段形成 2 个波峰, 其中归一化差值光谱在 2 个波峰处相关性最佳, 其次分别是比值光谱、差值光谱与原始光谱。

2.2.2 特征波长选择

利用 CARS 算法对水稻原始光谱与归一化差值光谱反射率进行特征波长的筛选, 根据交叉验证集 RMSECV 确定光谱特征波长后, 删去相邻的特征波长, 并通过相关性分析选取与 N_{and} 相关性最好的波长作为最佳特征波长, 以原始光谱选择过程为例: 由图 6a 可以看出, 随着运行次数的增加, 原始光谱被选出的波段数逐渐减少, 图 6b 中 RMSECV 整体呈下降趋势, 说明筛选过程中剔除的变量与 SOM 去除

量无关,而72次迭代以后,RMSECV呈回升趋势,表明反射率光谱中与SOM无关的大量信息或噪声被添加,从而导致RMSECV上升。图6c为所有变量在每次采样过程中的回归系数路径图,表示随着运

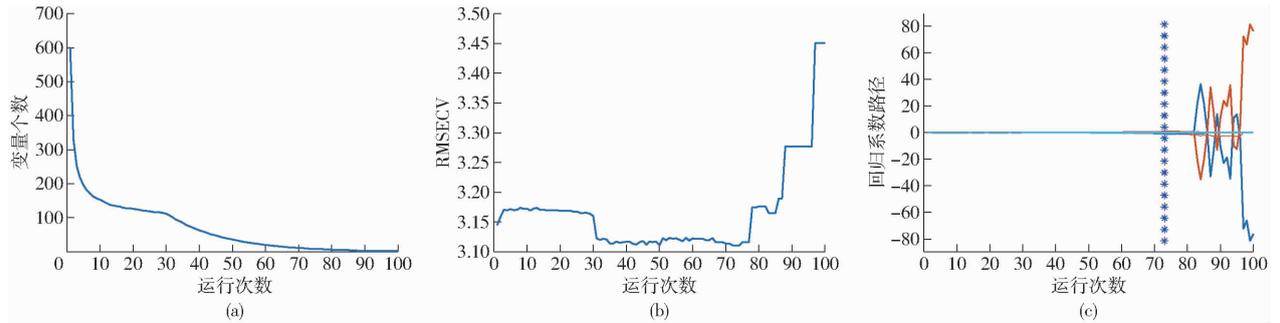


图6 原始光谱CARS降维结果

Fig. 6 CARS downscaling results of raw spectral

表2 CARS提取后原始光谱与变换后光谱特征波长与运行结果

Tab. 2 Raw spectra and processed spectra feature bands and run results under CARS

指标	运行次数	最小RMSECV	特征波长/nm
原始光谱	72	3.140 2	400, 411, 422, 447, 570, 677
比值光谱	56	2.983 3	533, 695, 715, 738, 774
差值光谱	68	2.776 4	413, 424, 444, 497, 533, 600, 676, 691
归一化差值光谱	82	2.493 5	484, 560, 644, 672, 695, 724

2.3 氮亏缺量反演模型构建

为比较不同光谱变换方法与反演建模方法的性能,分别以经CARS算法筛选出的原始光谱、比值光谱、差值光谱、归一化差值光谱特征波长为输入变量,水稻氮亏缺量为输出变量,分别构建基于MLR、ELM与BA-ELM的水稻氮亏缺量反演模型。

2.3.1 基于MLR的氮亏缺量反演

将4种光谱特征波长作为输入变量,分别构建基于MLR的反演模型,反演结果如图7所示:其中基于归一化差值光谱的模型精度最高,训练集与测试集的 R^2 分别为0.6540、0.7158, RMSE分别为

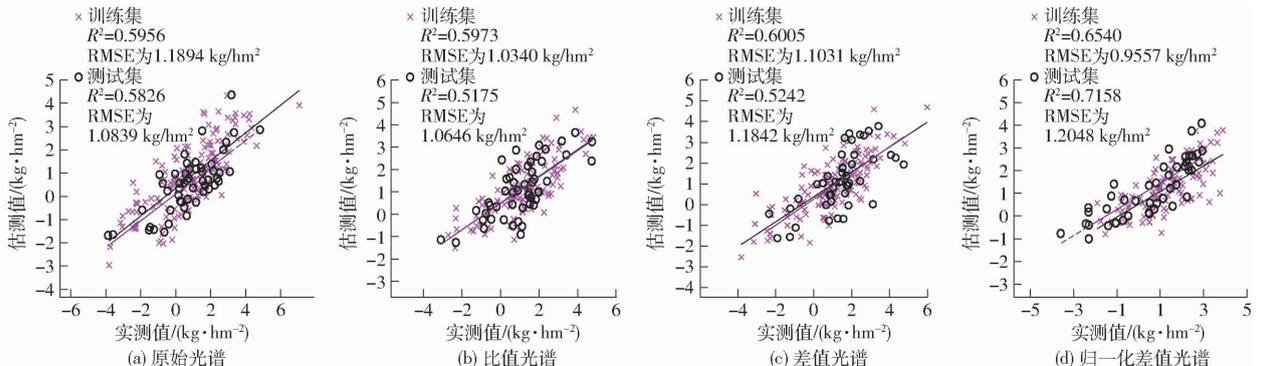


图7 基于MLR的不同反演模型结果

Fig. 7 Results of different inversion models based on MLR

行次数的增加各波段变量回归系数的变化趋势。结合图6b分析发现当运行次数为第72次时, RMSECV最小即所选择的光谱变量子集最优。原始光谱与3种变换光谱的特征选择结果如表2所示。

0.9557、1.2048 kg/hm²;其次是基于差值光谱反演模型,其 R^2 分别为0.6005、0.5242, RMSE分别为1.1031、1.1842 kg/hm²;然后是基于原始光谱的反演模型, R^2 分别为0.5956、0.5826, RMSE分别为1.1894、1.0839 kg/hm²。基于比值光谱的模型精度 R^2 分别为0.5973、0.5175, RMSE分别为1.0340、1.0646 kg/hm²;基于归一化差值光谱的反演模型反演效果最好。

2.3.2 基于ELM的氮亏缺量反演

将4种光谱特征波长作为输入变量,分别构建基于ELM的反演模型,映射函数为Sigmoid,隐含层个数分别为13、14、12、13,训练结果如图8所示。其中基于归一化差值光谱的模型精度最高,训练集与测试集的 R^2 分别为0.7211、0.6832, RMSE分别为0.8578、1.1512 kg/hm²;其次是基于比值光谱的反演模型, R^2 分别为0.6850、0.6344, RMSE分别为0.9145、0.9584 kg/hm²;然后是基于差值光谱反演模型,其 R^2 分别为0.6322、0.5994, RMSE分别为1.0570、1.0699 kg/hm²;最后是原始光谱的模型精度最低, R^2 分别为0.6192、0.5477, RMSE分别为1.1546、1.1753 kg/hm²。基于归一化差值光谱的

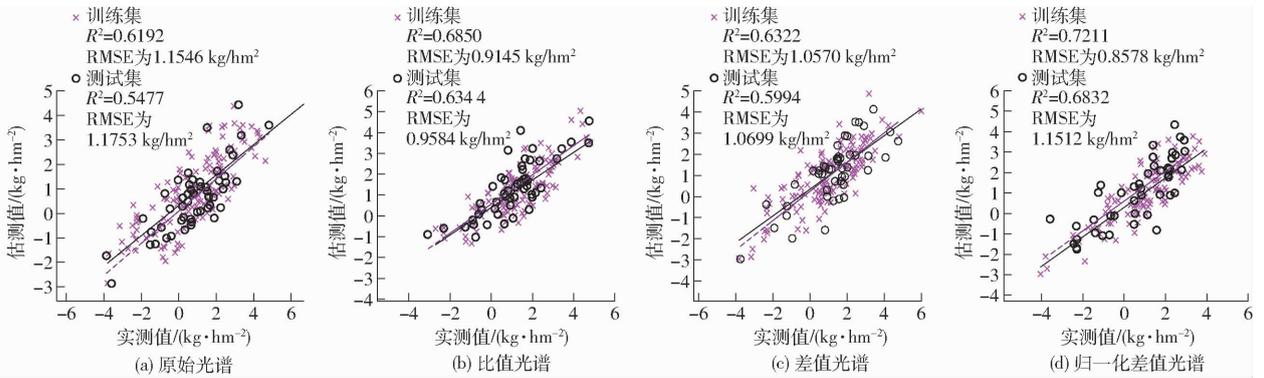


图 8 基于 ELM 的反演模型结果

Fig. 8 Results of inversion models based on ELM

反演模型 R^2 与 RMSE 均优于其余 3 种模型。

2.3.3 基于 BA-ELM 的氮亏缺量反演

将 4 种光谱特征波长作为输入变量,分别构建基于 BA-ELM 的反演模型,其中蝙蝠算法的最大迭代次数为 80,种群大小为 50,适应度函数为验证集 RMSE,隐含层个数分别为 50、60、57、65,结果如图 9 所示:基于归一化差值光谱的模型精度最高,训练集与验证集的 R^2 分别为 0.816 0、0.830 6, RMSE 为 0.696 8、0.814 1 kg/hm^2 ;基于比值光谱的模型精度 R^2 分别为 0.759 3、0.770 1, RMSE 分别为 0.799 4、0.730 9 kg/hm^2 ;基于差值光谱的模型精度 R^2 分别为 0.733 9、0.659 0, RMSE 分别为 0.900 3、0.997 1 kg/hm^2 ;原始光谱的模型精度,训练集与验

证集的 R^2 分别为 0.692 2、0.680 8, RMSE 为 1.037 5、0.952 8 kg/hm^2 。经过模型结果对比可知:基于 BA-ELM 的反演模型精度均优于基于 MLR 与 ELM 的反演模型;其中基于归一化差值光谱的反演模型在 R^2 与 RMSE 上均优于其余 3 种光谱模型;基于比值光谱在 MLR 模型中表现较差,但在 ELM 与 BA-ELM 模型中表现仅次于归一化差值光谱,这可能是由于比值光谱与氮亏缺量之间存在较为复杂的非线性关系,MLR 等线性模型对它的解释能力较差。在 3 种模型中,差值光谱与原始光谱表现相近,可见对光谱进行单纯的差值处理难以突出其与氮亏缺量的关系。因此采用基于归一化差值光谱的 BA-ELM 模型在反演水稻氮亏缺量上最有优势。

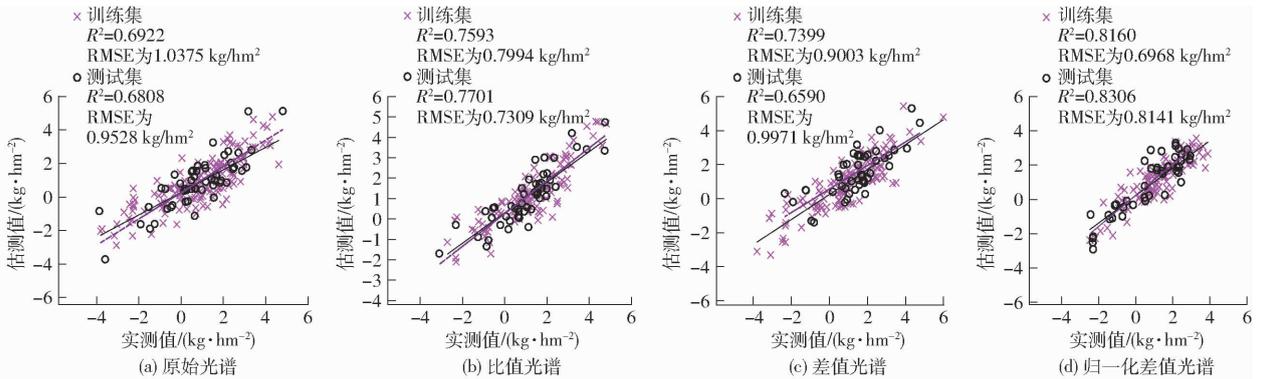


图 9 基于 BA-ELM 的反演模型结果

Fig. 9 Results of inversion models based on BA-ELM

2.4 针对不同施肥量的模型预测能力

在实验区 1 与实验区 2 中,以反演效果最优模型的氮亏缺量估测值与对应梯度的氮亏缺量实测值对比,结果如图 10 所示,实验区 1 与实验区 2 中,整体上估测值与实测值较为相近,对水稻氮亏缺量的估测能力较强;随着施氮量梯度的提升,对氮亏缺量的估测精度呈下降趋势,在临界氮浓度状态附近估测能力较差,这可能是因为临界氮浓度状态下与非临界氮浓度状态下水稻光谱变化规律不一致,模型同时估测 2 种状态的水稻光谱预测难度较高所致。

3 讨论

以往学者研究焦点往往集中在如何提高获取水稻田间氮浓度或氮营养指数信息的准确性^[28-29],然而这些信息只能描述水稻的氮营养状况,难以对水稻氮亏缺状况进行精确的定量描述,进而指导精准施肥。本文首先通过田间采样获取水稻氮浓度、地上生物量与冠层光谱数据,根据前人提出的方法构建东北水稻临界氮浓度曲线,并基于临界氮浓度曲线计算水稻氮亏缺量。由于临界氮浓度表示作物达

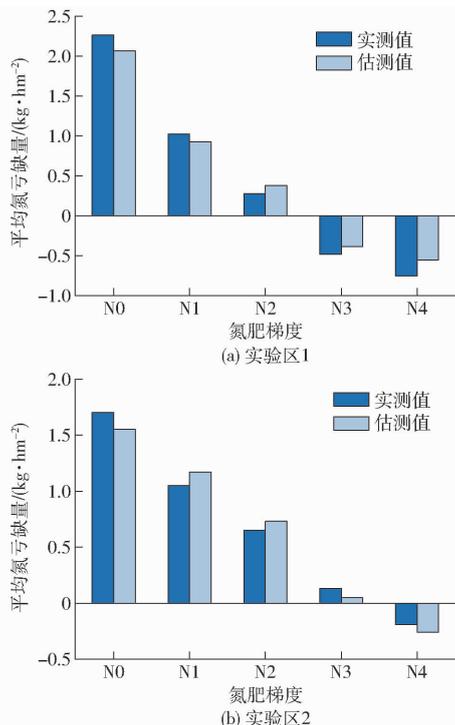


图 10 不同梯度氮亏缺量估测效果

Fig. 10 Estimated effect of different gradients of N deficit

到最大干物质量所需的最小氮浓度,以临界氮浓度作为判断水稻氮亏缺量的标准更能反映田间水稻的氮营养状况与实际氮需求情况。同时本研究还采用了无人机高光谱遥感技术与数据驱动的反演建模方法,通过水稻冠层光谱数据对氮亏缺量进行反演。无人机高光谱遥感技术能够快速、大面积获取水稻冠层光谱信息,进而对田间水稻氮营养状况进行快速诊断,数据驱动的反演建模方法虽然可解释性与泛化能力较差,但其能够对光谱与氮亏缺量之间的复杂非线性关系进行准确描述,将二者结合能够同时满足追肥决策所需的精确性与时效性,为定量追肥决策的实现提供了解决思路。

由于临界氮浓度状态下作物地上部氮营养状况与冠层叶片结构达到最佳状态,而这些都是影响水稻冠层光谱反射率的直接因素^[30],因此,相比非临界氮浓度状态下的作物,临界氮浓度下作物无论在光谱层面还是氮营养状况层面都存在一定差异。为了在光谱层面上放大临界氮浓度下水稻与其余水稻的差距,去除与氮亏缺量无关的冗余信息,本研究以各时期接近临界氮浓度状态下光谱为标准光谱,分别对原始光谱进行比值、差值、归一化差值变换,之后运用 CARS 算法提取变换光谱的特征波长。由结果可知 3 种光谱变换均提升了其与氮亏缺量之间的

相关性,其中归一化差值变换相关性与反演精度最高,这可能是由于归一化差值计算既通过差值计算放大了临界氮浓度光谱与其余冠层光谱的差异,又统一了差值光谱数据的量纲,还对光谱数据的统计分布性进行了归纳。

在建模过程中,本文选择蝙蝠算法优化 ELM 算法的初始权重,并将其与原始 ELM 进行对比建模。建模结果中 BA - ELM 模型的反演精度显著高于 ELM 模型,这可能是由于 ELM 作为一种基于前馈神经网络的机器学习算法,具有学习速度快,收敛能力强等优点,但同时也存在容易陷入局部最优解的问题;蝙蝠算法作为一种由粒子群算法衍生的元启发式搜索算法,在迭代过程中会在最优解附近再次搜索局部最优解,因此具有优秀的全局搜索能力,通过蝙蝠算法优化极限学习机的初始参数会让极限学习机在最优解附近开始学习,提高了算法的反演精度与全局搜索能力。

虽然本研究利用无人机高光谱数据对水稻氮亏缺量反演取得了较好的效果^[31],但对于实现基于无人机高光谱遥感的水稻精准追肥仍存在以下几点问题:①本文采用的归一化差值处理方法是基于各个采样期临界氮浓度状态的水稻光谱计算的,而这些光谱如果用于其他水稻光谱的计算时,可能会因为采样时间、水稻品种与发育状况等因素造成误差,进而影响氮亏缺量反演效果。②蝙蝠算法优化后的 ELM 算法也存在收敛精度不高,容易陷入局部最小值等问题。后续的研究重点应集中在如何在无人机高光谱数据中实时提取临界氮浓度状态下的水稻光谱与对反演算法的精度与鲁棒性进行优化这两方面上。

4 结论

(1) 构建了东北水稻临界氮浓度曲线,可表示为 $N_c = 2.026M^{-0.4603}$ 。

(2) 通过 CARS 算法提取的原始光谱、比值光谱、差值光谱与归一化差值光谱特征波长分别为 400、411、422、447、570、677 nm, 533、695、715、738、774 nm, 413、424、444、497、533、600、676、691 nm, 484、560、644、672、695、724 nm。

(3) 对比基于 4 种光谱特征波长与 ELM、BA - ELM 算法的 8 种建模方法反演精度可知,基于归一化差值的 BA - ELM 模型反演结果最好,训练集与测试集的 R^2 分别为 0.816 0、0.830 6, RMSE 为 0.696 8、0.814 1 kg/hm²。

参 考 文 献

[1] 王树文,赵越,王丽凤,等.基于高光谱的寒地水稻叶片氮素含量预测[J].农业工程学报,2016,32(20):187-194.

- WANG Shuwen, ZHAO Yue, WANG Lifeng, et al. Prediction for nitrogen content of rice leaves in cold region based on hyperspectrum[J]. Transactions of the CSAE, 2016, 32(20):187-194. (in Chinese)
- [2] FU Yuanyuan, YANG Guijun, PU Ruiliang, et al. An overview of crop nitrogen status assessment using hyperspectral remote sensing: current status and perspectives[J]. European Journal of Agronomy, 2021, 124:126241.
- [3] GREENWOOD D J, GASTAL F, LEMARIE G, et al. Growth rate and % N of field grown crops: theory and experiments[J]. Annals of Botany, 1991, 67(2):181-190.
- [4] LEMAIRE G, CHARRIER X, HÉBERT Y. Nitrogen uptake capacities of maize and sorghum crops in different nitrogen and water supply conditions[J]. Agronomie, 1996, 16(4):231-246.
- [5] 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 Yu'na, LI Fenling, WANG Weidong, et al. Monitoring of winter wheat nitrogen nutrition based on UAV hyperspectral images[J]. Transactions of the CSAE, 2020, 36(22):31-39. (in Chinese)
- [6] WANG X, MIAO Y, DONG R, et al. Machine learning-based in-season nitrogen status diagnosis and side-dress nitrogen recommendation for corn[J]. European Journal of Agronomy, 2021, 123:126193.
- [7] 吕茹洁,商庆银,陈乐,等.基于临界氮浓度的水稻氮素营养诊断研究[J].植物营养与肥料学报,2018,24(5):1396-1405.
LÜ Rujie, SHANG Qingyin, CHEN Le, et al. Study on diagnosis of nitrogen nutrition in rice based on critical nitrogen concentration[J]. Journal of Plant Nutrition and Fertilizers, 2018, 24(5):1396-1405. (in Chinese)
- [8] LIU Haiying, ZHU Hongchun, LI Zhenhai, et al. Quantitative analysis and hyperspectral remote sensing of the nitrogen nutrition index in winter wheat[J]. International Journal of Remote Sensing, 2020, 41(3):858-881.
- [9] 兰玉彬,王天伟,陈盛德,等.农业人工智能技术:现代农业科技的翅膀[J].华南农业大学学报,2020,41(6):1-13.
LAN Yubin, WANG Tianwei, CHEN Shengde, et al. Agricultural artificial intelligence technology: wings of modern agricultural science and technology[J]. Journal of South China Agricultural University, 2020, 41(6):1-13. (in Chinese)
- [10] 冯帅,曹英丽,许童羽,等.高光谱和 NSGA2-ELM 算法的梗稻叶片氮素含量反演[J].光谱学与光谱分析,2020,40(8):2584-2591.
FENG Shuai, CAO Yingli, XU Tongyu, et al. Inversion based on high spectrum and NSGA2-ELM algorithm for the nitrogen content of japonica rice leaves[J]. Spectroscopy and Spectral Analysis, 2020, 40(8):2584-2591. (in Chinese)
- [11] SHI Peihua, WANG Yuan, XU Jianmin, et al. Rice nitrogen nutrition estimation with RGB images and machine learning methods[J]. Computers and Electronics in Agriculture, 2021, 180:105860.
- [12] ATA-UI-KARIM S T, LIU X, LU Z, et al. Estimation of nitrogen fertilizer requirement for rice crop using critical nitrogen dilution curve[J]. Field Crops Research, 2017, 201:32-40.
- [13] 李鑫格,项方林,吴思雨,等.基于植被指数时序动态的冬小麦氮素营养诊断方法[J].麦类作物学报,2022,42(1):109-119.
LI Xingge, XIANG Fanglin, WU Siyu, et al. Diagnosis methods for nitrogen status based on the time-series vegetation index in winter wheat[J]. Journal of Triticeae Crops, 2022, 42(1):109-119. (in Chinese)
- [14] ZHA Hainie, MIAO Yuxin, WANG Tiantian, et al. Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning[J]. Remote Sensing, 2020, 12(2):215.
- [15] QIU Zhengchao, MA Fei, LI Zhenwang, 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
- [16] JUSTES E, MARY B, MEYNARD J M, et al. Determination of a critical nitrogen dilution curve for winter wheat crops[J]. Annals of Botany, 1994, 74(4):397-407.
- [17] LEMAIRE G, JEUFFROY M H, GASTAL F. Diagnosis tool for plant and crop N status in vegetative stage. Theory and practices for crop N management[J]. European Journal of Agronomy, 2008, 28(4):614-624.
- [18] LEMAIRE G, SINCHAIR T, SADRAS V, et al. Allometric approach to crop nutrition and implications for crop diagnosis and phenotyping. A review[J]. Agronomy for Sustainable Development, 2019, 39(2):27.
- [19] 杨红云,周琼,杨璐,等.基于高光谱的水稻叶片氮素营养诊断研究[J].浙江农业学报,2019,31(10):1575-1582.
YANG Hongyun, ZHOU Qiong, YANG Jun, et al. Study on nitrogen nutrition diagnosis of rice leaves based on hyperspectrum[J]. Acta Agriculturae Zhejiangensis, 2019, 31(10):1575-1582. (in Chinese)
- [20] CHEN Shaoming, HU Tiantian, LU Lihua, et al. Rapid estimation of leaf nitrogen content in apple-trees based on canopy hyperspectral reflectance using multivariate methods[J]. Infrared Physics and Technology, 2020, 111:103542.
- [21] 张晶,张珏,田海清.基于高光谱成像技术的甜菜叶片氮素遥感估测[J].中山大学学报(自然科学版),2018,57(6):103-112.
ZHANG Jing, ZHANG Jue, TIAN Haiqing. Remote sensing estimation research of leaf nitrogen sugar beet based on hyperspectral imaging[J]. Acta Scientiarum Naturalium Universitatis Sunyatseni, 2018, 57(6):103-112. (in Chinese)
- [22] 陆军胜,陈绍民,黄文敏,等.采用 SE_(PLS)_ELM 模型估算夏玉米地上部生物量和叶面积指数[J].农业工程学报,2021,37(18):128-135.
LU Junsheng, CHEN Shaomin, HUANG Wenmin, et al. Estimation of aboveground biomass and leaf area index of summer maize using SE_(PLS)_ELM model[J]. Transactions of the CSAE, 2021, 37(18):128-135. (in Chinese)
- [23] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks[C]// IEEE International Joint Conference on Neural Networks. IEEE, 2005.

- [19] VIALET-CHABRAND S, BRENDEL O. Automatic measurement of stomatal density from microphotographs[J]. *Trees*, 2014, 28(8): 1859 – 1865.
- [20] JAYAKODY H, LIU S, WHITTY M, et al. Microscope image based fully automated stomata detection and pore measurement method for grapevines[J]. *Plant Methods*, 2017, 13(11): 94.
- [21] XIE J, FERNANDES S, DUSTIN M, et al. Optical topometry and machine learning to rapidly phenotype stomatal patterning traits for maize QTL mapping[J]. *Plant Physiology*, 2021, 187(3): 1462 – 1480.
- [22] AONO A, NAGAI J, DICKEL G, et al. A stomata classification and detection system in microscope images of maize cultivars [J]. *PLoS ONE*, 2021, 16(10): e0258679.
- [23] FETTER K, EBERHARDT S, BARCLAY R, et al. StomataCounter: a neural network for automatic stomata identification and counting[J]. *New Phytologist*, 2019, 223(3): 1671 – 1681.
- [24] JAYAKODY H, PETRIE P, BOER H, et al. A generalised approach for high-throughput instance segmentation of stomata in microscope images[J]. *Plant Methods*, 2021, 17(1): 1 – 13.
- [25] XIANG Z, SEELING P, FITZEK F. You only look once, but compute twice: service function chaining for low-latency object detection in softwarized networks[J]. *Applied Sciences*, 2021, 11(5): 2177.
- [26] YANG N, LU Y, YANG X, et al. Genome wide association studies using a new nonparametric model reveal the genetic architecture of 17 agronomic traits in an enlarged maize association panel[J]. *Plos Genetics*, 2014, 10(9): 1004573.
- [27] 朱济友, 徐程扬, 吴鞠. 基于 eCognition 植物叶片气孔密度及气孔面积快速测算方法[J]. *北京林业大学学报*, 2018, 40(5): 41 – 49.
ZHU Jiyu, XU Chengyang, WU Ju. Fast estimation of stomatal density and stomatal area of plant leaves based on eCognition [J]. *Journal of Beijing Forestry University*, 2018, 40(5): 41 – 49. (in Chinese)
- [28] CASADO-GARCIA N, DOMINGUEZ C, GARCIA-DOMINGUEZ M, et al. CLoDSA: a tool for augmentation in classification, localization, detection, semantic segmentation and instance segmentation tasks[J]. *BMC Bioinformatics*, 2019, 20(1): 1 – 14.
- [29] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. *arXiv: 1804.02767*, 2018.
- [30] 张宏鸣, 付振宇, 韩文霆, 等. 基于改进 YOLO 的玉米幼苗株数获取方法[J]. *农业机械学报*, 2021, 52(4): 221 – 229.
ZHANG Hongming, FU Zhenyu, HAN Wenting, et al. Detection method of maize seedlings number based on improved YOLO [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(4): 221 – 229. (in Chinese)
- [31] TIAN D, LIN C, ZHOU J, et al. SA – YOLOv3: an efficient and accurate object detector using self-attention mechanism for autonomous driving[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(5): 24099 – 24110.
- [32] LIU Y, ZHANG Z, LIU X, et al. Ore image classification based on small deep learning model; evaluation and optimization of model depth, model structure and data size[J]. *Minerals Engineering*, 2021, 172(10): 107020.
- [33] KOLOURI S, YIN X, ROHDE G. Neural networks, hypersurfaces, and the generalized radon transform[J]. *IEEE Signal Processing Magazine*, 2020, 37(4): 123 – 133.

(上接第 197 页)

- [24] AL-BETAR M A, AWADALLAH M A, FARIS H, et al. Bat-inspired algorithms with natural selection mechanisms for global optimization[J]. *Neurocomputing*, 2018, 273: 448 – 465.
- [25] 寇英信, 奚之飞, 徐安, 等. 基于改进核极限学习机和集成学习理论的目标机动轨迹预测[J]. *国防科技大学学报*, 2021, 43(5): 23 – 35.
KOU Yingxin, XI Zhifei, XU An, et al. Maneuver trajectory prediction of target based on improved KELM and ensemble learning theory[J]. *Journal of National University of Defense Technology*, 2021, 43(5): 23 – 35. (in Chinese)
- [26] DONG J, WU L, LIU X, et al. Estimation of daily dew point temperature by using bat algorithm optimization based extreme learning machine[J]. *Applied Thermal Engineering*, 2019, 165: 114569.
- [27] SONG L, WANG S, YE W. Establishment and application of critical nitrogen dilution curve for rice based on leaf dry matter [J]. *Agronomy*, 2020, 10(3): 367.
- [28] 徐浩聪, 姚波, 王权, 等. 基于叶片反射光谱估测水稻氮营养指数[J]. *中国农业科学*, 2021, 54(21): 4525 – 4539.
XU Haocong, YAO Bo, WANG Quan, et al. Determination of suitable band width for estimating rice nitrogen nutrition index based on leaf reflectance spectra[J]. *Scientia Agricultura Sinica*, 2021, 54(21): 4525 – 4539. (in Chinese)
- [29] 王晓珂, 刘婷婷, 许桂玲, 等. 基于冠层高光谱遥感的杂交水稻植被指数氮素营养诊断模型[J]. *中国稻米*, 2021, 27(3): 21 – 29.
WANG Xiaoke, LIU Tingting, XU Guiling, et al. Nitrogen diagnosis model of vegetation indices based on canopy hyperspectral remote sensing for hybrid rice[J]. *China Rice*, 2021, 27(3): 21 – 29. (in Chinese)
- [30] LI Xinyu, SYEO Tahir Ata-UI-Karim, LI Yue, et al. Advances in the estimations and applications of critical nitrogen dilution curve and nitrogen nutrition index of major cereal crops. A review[J]. *Computers and Electronics in Agriculture*, 2022, 197: 106998.
- [31] 王鑫梅, 张劲松, 孟平, 等. 基于无人机遥感影像的核桃冠层氮素含量估算[J]. *农业机械学报*, 2021, 52(2): 178 – 187.
WANG Xinmei, ZHANG Jinsong, MENG Ping, et al. Estimation of nitrogen content in walnut canopy based on UAV remote sensing image[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(2): 178 – 187. (in Chinese)