doi:10.6041/j.issn.1000-1298.2025.07.049

基于 NSWOA－ELM 算法的水稻冠层氮素含量反演方法

于丰华[1,2]　曹慧妮[1,2]　金忠煜[1,2]　王　楠[1,2]　李世隆[1,2]　孙道明[1,2]　许童羽[1,2]
(1.沈阳农业大学信息与电气工程学院,沈阳 110866;2.国家数字农业区域创新分中心(东北),沈阳 110866)

摘要:以水稻为研究对象,获取波长 400～1 000 nm 范围内的水稻冠层高光谱反射率。采用 Savitzky－Golay 卷积平滑方法对高光谱数据进行预处理,并通过连续投影算法(Successive projections algorithm, SPA)选择特征波长。在此基础上,提出了一种基于多目标鲸鱼优化算法(Non-dominated Sorting whale optimization algorithm, NSWOA)优化的极限学习机(Extreme learning machine, ELM)模型,用于反演水稻冠层氮素含量。利用误差反向传播神经网络(Back propagation neural network, BPNN)和 ELM 模型,与 NSWOA 优化后的 ELM 模型进行对比。结果表明,SPA 算法筛选出的特征波长为 400、440、487、542、589、660、675、739、766、808、878、912、949 nm。使用筛选后的特征波长反射率构建 NSWOA－ELM 水稻冠层氮素含量反演模型效果最好,训练集 R^2 为 0.859 3,RMSE 为 0.200 2 mg/g;验证集 R^2 为 0.854 3,RMSE 为 0.206 9 mg/g。与 BP 神经网络和 ELM 模型相比,NSWOA－ELM 在预测能力和模型稳定性方面具有显著优势。综上,基于 NSWOA－ELM 的水稻冠层氮素含量反演模型能够为水稻生长状况的描述及精准施肥提供可靠支持。

关键词:水稻冠层;氮素;高光谱;多目标鲸鱼优化算法;极限学习机
中图分类号:S511　　**文献标识码**:A　　**文章编号**:1000-1298(2025)07-0532-09　　**OSID**:

Inversion Method of Nitrogen Content in Rice Canopy Based on NSWOA－ELM Algorithm

YU Fenghua[1,2]　CAO Huini[1,2]　JIN Zhongyu[1,2]　WANG Nan[1,2]　LI Shilong[1,2]　SUN Daoming[1,2]　XU Tongyu[1,2]
(1. *College of Information and Electrical Engineering*, *Shenyang Agricultural University*, *Shenyang* 110866, *China*
2. *National Digital Agriculture Sub-center of Innovation* (*Northeast Region*), *Shenyang* 110866, *China*)

Abstract: Rice was selected as the research subject, and hyperspectral reflectance data of the rice canopy within the range of 400～1 000 nm was collected experimentally. To preprocess this data, the Savitzky－Golay smoothing method was applied, followed by the successive projections algorithm (SPA) to identify characteristic wavelengths. Based on the processed spectral data, an extreme learning machine (ELM) model optimized by the non-dominated sorting whale optimization algorithm (NSWOA) was developed to estimate the nitrogen content in the rice canopy. To evaluate its performance, the NSWOA optimized ELM model was compared with a traditional back propagation neural network (BPNN) and a standard ELM model. The results indicated that the characteristic wavelengths identified by the SPA algorithm were 400 nm, 440 nm, 487 nm, 542 nm, 589 nm, 660 nm, 675 nm, 739 nm, 766 nm, 808 nm, 878 nm, 912 nm and 949 nm. The NSWOA－ELM model based on reflectance at these selected wavelengths performed best, achieving a determination coefficient (R^2) of 0.859 3 for the training set and 0.854 3 for the validation set, with root mean square errors (RMSE) of 0.200 2 mg/g and 0.206 9 mg/g, respectively. Compared with the BPNN and standard ELM models, the NSWOA－ELM model demonstrated superior predictive accuracy and model stability. In conclusion and generalization, the NSWOA－ELM rice canopy nitrogen inversion model provided a reliable approach for assessing rice growth conditions and supporting precision fertilization strategies.

Key words: rice canopy; nitrogen; hyperspectral; non-dominated sorting whale optimization algorithm; extreme learning machine

收稿日期:2025－01－07　修回日期:2025－02－18
基金项目:辽宁省教育厅平台项目(JYTPT2024002)、国家自然科学基金青年项目(32201652)和辽宁省自然科学基金面上项目(2023－MSLH－283)
作者简介:于丰华(1989—),男,教授,主要从事精准农业航空研究,E-mail:adan@syau.edu.cn
通信作者:许童羽(1967—),男,教授,博士生导师,主要从事农业信息化研究,E-mail:xutongyu@syau.edu.cn

0　引言

氮素是水稻生长发育中不可或缺的营养元素之一，对植物光合作用至关重要[1]。氮素缺乏会影响植被进行光合作用，进而导致植株早衰等问题，影响品质及产量，通过分析植株冠层反射光谱，能够有效监测和评估氮素含量的变化[2]。快速评估作物的营养状况、准确掌握水稻冠层氮素含量对于田间管理和作物生长的健康至关重要[3-4]。然而，传统的氮素检测方法依赖于化学分析，虽然结果精确，但耗时长且具有破坏性，难以满足现代精准农业对快速、无损检测的需求[5]。因此，凭借快速、无损的特点，高光谱遥感技术在作物营养监测和氮素含量反演研究中得到了广泛应用[6]。

近年来，高光谱遥感技术已广泛应用于包括水稻在内的作物营养监测，通过高光谱数据实现对水稻主要营养元素的定量反演和营养状况诊断，已成为国内外学者关注的研究重点之一[7-9]。CAO 等[10]提出了一种基于无人机高光谱成像数据的反演模型，用于预测粳稻冠层叶绿素含量，该研究通过特征波段选择技术和粒子群优化算法优化极限学习机的参数，从而提高模型的准确性和泛化能力。ZHANG 等[11]提出了一种利用无人机高光谱成像技术监测冬小麦生长和氮素状况的方法。研究表明，高光谱遥感技术在作物生长监测方面应用前景广阔，然而，如何进一步提高反演精度和适应性，仍是当前研究中的难点。

在构建农作物营养元素反演模型过程中，线性模型与机器学习技术被广泛应用[12]。为进一步提升模型预测精度，研究者开始采用仿生优化算法进行优化。仿生优化算法通过模拟自然界生物行为来解决问题，在复杂度较高的情况下展现出强大的搜索能力，成为提升预测精度的重要工具[13-14]。仿生优化算法在多个领域的应用中发挥了重要作用，尽管如此，这些算法在收敛速度、稳定性和参数调节方面仍存在局限性，限制了模型的适应性和泛化能力。

综上所述，为提高水稻氮素含量预测的准确性和稳定性，本文提出一种基于多目标鲸鱼优化算法（NSWOA）优化的极限学习机（ELM）模型，用于反演水稻冠层氮素含量。

1　材料与方法

1.1　研究区概况

本试验于 2023 年 7—8 月，在辽宁省海城市耿庄镇（北纬 40°58′45.39″，东经 122°43′47.00″）的沈阳农业大学海城实训基地开展。该地区属于温带大陆性季风气候，年均降水量为 652 mm，年平均气温为 8.4℃，年日照时数约 2 543 h，提供了适宜水稻生长的自然条件。试验选用的水稻品种是“沈农 9816”，并分别在水稻分蘖期、拔节期、孕穗期和抽穗期，测量水稻冠层高光谱反射率，同时测定水稻冠层氮素含量。研究区概况如图 1 所示，其中大田1～11 号小区，每个小区面积为 660 m^2；小田 12～26 号小区，每个小区面积为 40 m^2。小区试验设 5 个氮肥梯度，分别为零氮肥（N0）、低氮肥（N1）、中氮肥（N2）、标准氮肥（N3）、高氮肥（N4），其中 N0 不施用任何氮肥；N3 为 220.5 kg/hm^2，按照底肥、分蘖肥、穗肥比例 5∶3∶2 施用；N1、N2、N4 分别在 N3 的基础上减 50%、减 25%、加 25%，具体试验小区分布如图 1 所示，所有小区的田间管理策略保持一致。

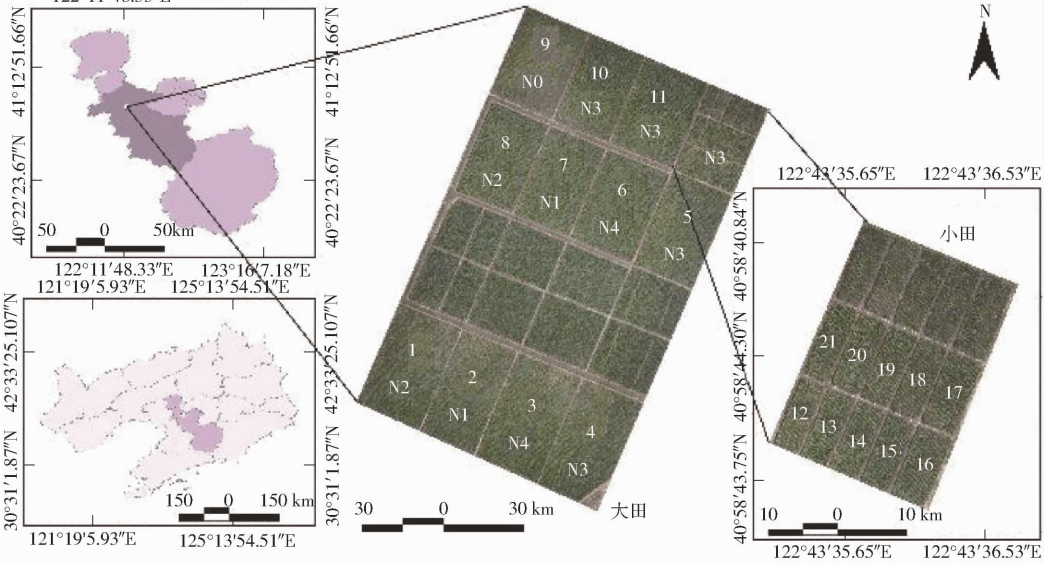


图 1　研究区概况

Fig. 1　Overview of study area

1.2 数据获取

1.2.1 高光谱数据获取

试验选择奥普天成 ATP9110 - 25 型地物光谱仪作为关键测量工具,光谱检测波长为 281 ~ 2 516 nm。光谱仪的采样间隔在可见光区域为 0.405 nm,在短波红外区域为 1.361 nm。试验选择在水稻分蘖期、拔节期、孕穗期和抽穗期并确保测量在晴朗无云的条件下,于 10:00 至 14:00 之间(太阳高度角大于 45°)进行。测量时,光谱仪传感器探头垂直朝下,与水稻冠层顶端保持约 0.15 m 的垂直距离。测量水稻冠层的高光谱时,随机在每个试验小区选择 4 个不同位置,记录光谱数据后,取测量平均值作为该采样点的光谱反射率。采样后,将样品装入密封袋带回实验室进行下一步氮素含量测定。测量数据前,为确保数据准确性,使用标准白板对仪器进行校准。为减少光谱噪声影响,去掉 281 ~ 400 nm 及1 000 nm 以上的波段,对波段范围内的光谱数据进行氮素含量的后续反演分析。高光谱原始数据预处理包含重采样及高斯平滑 2 个阶段。奥普天成地物光谱仪采集的高光谱数据受环境因素的影响,会产生噪声波段,若直接使用原始光谱数据构建反演模型会降低氮素预测的精度。因此,首先对平均光谱进行重采样,得到分辨率为 1 nm 的高光谱曲线。随后,使用 Savitzky - Golay 卷积平滑算法对重采样后的数据进行处理,生成的高光谱曲线更加平滑,接近真实的光谱曲线。

1.2.2 氮素含量测定

对水稻分蘖期、拔节期、孕穗期和抽穗期氮素含量进行测定。在各试验小区的采样点进行整穴破坏性取样后,将水稻置于低温保温箱内带回实验室。将水稻样本放入 105℃ 干燥箱中杀青 30 min,随后在 80℃下烘干至恒定质量。将烘干样品研磨成粉末后过筛,再采用凯氏定氮法检测叶片氮素含量应用蒙特卡洛算法剔除异常光谱数据后,最终得到 112 组有效的水稻冠层氮素含量。获得的有效数据经过 Kolmogorov - Smirnov(KS)检验,并按比例 8∶2划分为训练集和验证集,其中训练集包含 90 组数据,验证集包含 22 组数据。表 1 为水稻叶片氮素含量统计结果。为了更加直观地反映各生育期样本分布情况,对不同生育期水稻样本数量进行统计,具体结果如表 2 所示。

表 1 水稻叶片氮素含量统计结果

Tab.1 Statistics of nitrogen content in rice leaves

样本集	样本数量	最小值/(mg·g⁻¹)	最大值/(mg·g⁻¹)	平均值/(mg·g⁻¹)	标准偏差/(mg·g⁻¹)
训练集	90	0.158	2.579	1.495	0.537
验证集	22	0.487	2.109	1.468	0.516

表 2 不同生育期水稻样本数量

Tab.2 Statistics of rice quantity at different growth stages

参数	分蘖期	拔节期	孕穗期	抽穗期
训练集样本数量	17	39	12	22
验证集样本数量	3	12	3	4

1.3 筛选特征波长

由于地物光谱仪获取的水稻冠层高光谱数据具有高维度,并包含大量冗余信息,直接使用原始数据进行反演建模不仅会显著增加计算时间,还可能降低模型的反演精度。连续投影算法(Successive projections algorithm, SPA)是一种常用的前向变量选择算法,能够有效最小化向量空间中的共线性,通常用于筛选光谱特征变量[15]。因此,本研究利用 SPA 从高光谱数据中提取特征,并将提取的特征波长光谱反射率作为后续反演模型的输入。

SPA 算法首先选择一个波长,再在每次迭代中与另一个变量合并,直到达到预定义的变量数量。该方法旨在选择冗余光谱信息最少的波长,从而有效解决共线性问题。SPA 以分析光谱矩阵 $\boldsymbol{X}$、初始波段 $k(0)$、选择变量个数 N 为输入,选择的波段为输出,主要步骤如下:

(1)初始化。

设置 $r=1$,$\boldsymbol{x}_j \in \boldsymbol{X}_j$, $j=1,2,\cdots,J$,其中,r 为迭代次数,J 为波段总数,$\boldsymbol{x}_j$ 为光谱矩阵 $\boldsymbol{X}$ 中的第 j 个波段,$\boldsymbol{X}_j$ 为第 j 个波段相关的光谱数据集合。

(2)确定未选择波段的变量 S。

$$S=\{\boldsymbol{X}_i, 1\leqslant i\leqslant J, i\notin\{k(0),k(1),\cdots,k(N-1)\}\} \tag{1}$$

式中 i——波段索引,用于遍历所有波段

$k(0),k(1),\cdots,k(N-1)$——已经被选择的波段序列

$\boldsymbol{X}_i$——第 i 个波段相关的光谱数据集合

(3)计算未选择和初始化波段的投影映射。

$$P_{x_j}=\boldsymbol{x}_j-(\boldsymbol{x}_j^{\mathrm{T}}\boldsymbol{x}_i)\boldsymbol{x}_i(\boldsymbol{x}_i^{\mathrm{T}}\boldsymbol{x}_i)^{-1} \quad (\boldsymbol{x}_i\in S) \tag{2}$$

式中 P_{x_j}——正交投影

$\boldsymbol{x}_i$——光谱矩阵 $\boldsymbol{X}$ 中的第 i 个波段

(4)确定最大投影。

$$k(r)=\max(\|P_{x_j}\|) \quad (\boldsymbol{x}_j\in S) \tag{3}$$

式中 $k(r)$——第 r 次迭代选中的波段

(5)赋值。

$$\boldsymbol{x}_j=P_{x_j} \quad (x_j\in S) \tag{4}$$

(6)确定波段选择顺序 $\{k(r); r=0,1,\cdots,N-1\}$。

1.4 建模方法

1.4.1 BPNN 模型

误差反向传播神经网络(Back propagation

neural network，BPNN）是一种多层前馈神经网络，它包含输入层、隐藏层和输出层，各层之间通过权值连接在一起[16]。首先，神经元接收来自前几层的输入，而后使用激活函数计算加权和，减去阈值并传递到下一层，然后，计算真实值和预测值之间的误差，并通过反向传播算法传回，权重和阈值因误差而更新，并在多次迭代后将误差最小化[17]，不断逼近期望输出的结果。

BP 神经网络隐含层节点数量对其预测精度有显著影响。隐含层节点数范围计算公式为

$$l = \sqrt{m+n} + a \tag{5}$$

式中　l——隐含层节点数

m——输入层节点数

n——输出层节点数

a——0～10 之间的常数

通过设置循环命令、多次试验确定最佳隐含层节点数，当训练达到目标误差或最大迭代次数时，跳出循环。通过反复训练，获得效果较佳的传递函数和训练函数。

1.4.2　ELM 模型

极限学习机（Extreme learning machine，ELM）是一种基于前馈神经网络的机器学习算法，已广泛应用于遥感反演领域[18－21]。与传统的前馈神经网络相比，ELM 解决了传统神经网络参数选择复杂等缺点，具有学习效率高、精度高、参数调整简单等优点。ELM 模型广泛应用于模式识别和非线性拟合[18]。极限学习机可以看作是一个单隐层网络，其内部是完全连通的。当输入层、输出层的神经元数量分别为 m、n，隐含层的神经元数量为 l 时，ELM 网络结构如图 2 所示。

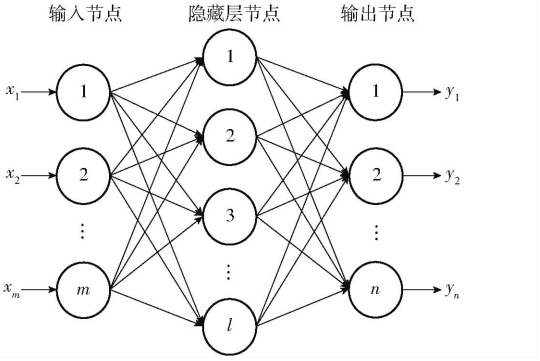


图 2　ELM 网络结构

Fig. 2　ELM network topology

ELM 的优势主要体现在以下几个方面：首先训练速度快，由于输入权重和偏置是随机生成的，并且输出权重可以通过一次性计算得到，ELM 避免了传统神经网络反向传播算法的迭代过程，大幅缩短了训练时间。其次 ELM 泛化能力强，ELM 的随机权重生成机制和最小二乘法的应用，使其具有较强的泛化能力，能够在复杂数据集上表现出较好的预测性能。除此之外，ELM 的实现过程较为简单，参数调节相对较少，实现了在实际应用中快速部署与高效应用。

1.4.3　基于 NSWOA 寻优的 ELM

智能优化算法灵感源自自然界的生物智能机制或物理现象，构成了一类高效的随机搜索策略。这类算法显著特点在于不依赖于目标函数及约束条件的连续性或凸性，展现出了对复杂问题中数据不确定性的强大适应能力。鉴于这些优势，将智能优化算法应用于极限学习机（ELM）的优化过程中，旨在通过算法的智能搜索能力，提升 ELM 模型的性能，进而实现反演精度增强和误差显著降低。这一策略有效融合了机器学习的灵活性与优化算法的智能性，为解决复杂系统建模与预测问题提供了有力工具。多目标鲸鱼优化算法（Non-dominated sorting whale optimization algorithm，NSWOA）[22]优化极限学习机是在 ELM 算法基础上提出的一种改进方法。传统 ELM 模型存在精度不高、误差较大的问题，且在处理复杂数据时，容易陷入局部最优解，难以找到全局最优解。此外，对于复杂的非线性关系，基础 ELM 的特征提取能力有限，从而影响了模型的预测精度。因此，本研究提出一种将多目标鲸鱼优化算法与 ELM 模型相结合的混合算法。该混合算法引入了多目标优化相关理论，通过利用非支配排序等方法对鲸鱼进行选择和排序，提升了模型的全局搜索能力和预测精度。NSWOA 优化过程为：

（1）初始化系统参数并定义迭代次数，生成控制器参数的初始总体，这些参数将在优化时考虑在内。在这项工作中，鲸鱼的初始种群（即搜索代理）的大小取为 80。

（2）使用适应度函数评估每个搜索代理的适应度，生成初始适应度 O，并根据适应度值对搜索代理进行非支配排序，计算当前人群的下一步拥挤距离和排名。

（3）根据 3 种策略更新搜索代理的位置：①包围猎物，即模拟座头鲸逐渐靠近并包围猎物的行为，搜索代理根据当前最优解调整位置，逐步缩小与目标猎物的距离。②螺旋定位，即模拟座头鲸沿螺旋路径接近猎物，增强局部搜索的精确程度。③随机搜索，为避免陷入局部最优，引入随机性，一部分代理继续围绕猎物搜索，另一部分随机探索新位置，便于提高全局搜索能力。

（4）评估搜索代理的适应度函数值，生成新的适应度 N_f，将初始适应度 O 与其合并，生成长度为

$O+N_f$ 的解向量。

(5)对新的解向量进行非支配排序,循环从步骤(3)运行到步骤(5),直到达到最大迭代次数且满足停止标准。在循环结束后确定搜索代理的最佳可能位置,即为最优解。

(6)根据最优解设置 ELM 基本参数、最优权值和阈值。

(7)计算误差,若误差在允许范围,则输出结果,反之,则重复步骤(6),继续优化迭代,直到误差达到可接受的标准为止。

模型整体优化流程图如图 3 所示。

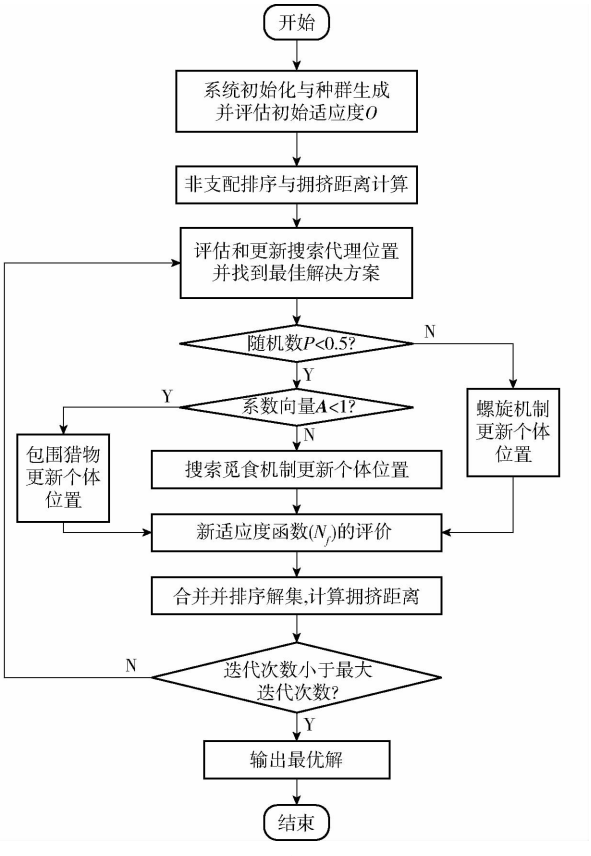


图 3 基于 NSWOA 优化 ELM 的流程图

Fig. 3 Flowchart of ELM based on NSWOA

1.4.4 水稻冠层氮素含量遥感建模与模型评价

采用 BPNN、ELM 以及 NSWOA - ELM 3 种支持多元回归输出的神经网络模型进行建模,分别通过决定系数 R^2 及均方根误差(Root mean square error, RMSE)对模型的精确度和可靠性进行评估,以比较不同模型在水稻冠层氮素含量反演中的表现。

2 结果与分析

2.1 高光谱数据处理

高光谱原始数据分别经过重采样和 Savitzky - Golay 卷积平滑处理,以提高数据质量。重采样后,高光谱分辨率为 1 nm,有效减少了噪声带来的影响。经过预处理后的高光谱曲线更加平滑接近真实的光谱曲线,使其在后续的氮素反演中更加可靠。经过处理的高光谱数据如图 4 所示,为模型准确性提供了更有力的支持。

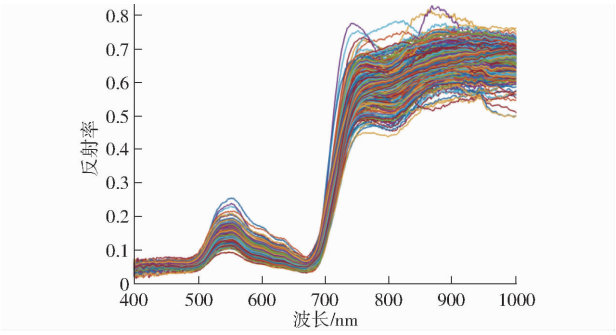


图 4 高光谱信息平滑降噪处理结果

Fig. 4 Smooth noise reduction processing of hyperspectral information

2.2 特征波长选择

为建立水稻冠层氮素含量反演模型,首先利用 Matlab R2022b 软件平台进行特征波长选择,应用连续投影算法(SPA)对水稻冠层的高光谱数据进行特征筛选。为了优化模型,设置波段筛选个数范围为 10 ~ 20。随后,利用验证集进行内部交叉验证,针对所选波段进行性能评估。通过计算验证结果的均方根误差,筛选出最能反映水稻生物量的高光谱特征波长。当 RMSE 达到最低值时,对应的子集波长即被确定为最优波长数据。结果如图 5 所示,利用连续投影算法进行特征波长筛选时,随着筛选变量数增加,RMSE 整体呈下降趋势。RMSE 取最低值 0.299 时,提取到光谱特征波长共 13 个,分别为 400、440、487、542、589、660、675、739、766、808、878、912、949 nm,这些特征光谱变量占原始波段数的 2.2%,实现了降维。将这 13 个反射率波长作为模型的输入变量。

2.3 水稻冠层氮素含量反演模型构建与分析

使用 SPA 筛选出的 13 个特征波长的反射率作为模型输入,以水稻冠层氮素含量作为模型输出变量,分别构建了 BPNN、ELM 以及 NSWOA - ELM 3 种反演模型。模型参数经优化调整后,得到的各模型建模结果如图 6 所示。其中,设置 BPNN 模型隐含层神经元数量为 40,最大迭代次数为 50,结果显示其氮素训练集和验证集决定系数 R^2 分别为 0.729 9、0.725 9,RMSE 分别为 0.291 8、0.315 mg/g。相较而言,该模型的表现位于中间水平。与 BPNN 相比,ELM 模型表现欠佳,设置 30 个隐含层节点的 ELM 模型在训练集和验证集上表现显著下滑,其决定系数 R^2 分别为 0.712 9、0.604 1,RMSE 分别为 0.285 9、0.346 6 mg/g,表明该模型在精度和稳定性方面均存

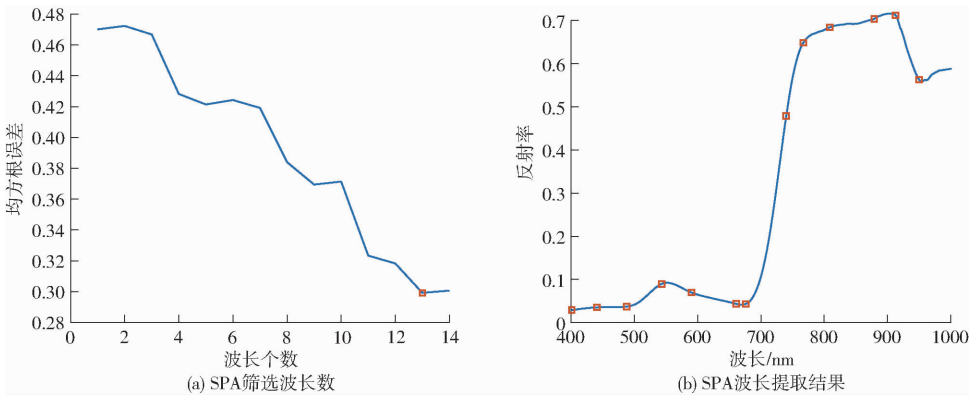


图 5　水稻冠层高光谱反射率特征波长选择结果

Fig. 5　Results of spectral reflectance characteristic band selection of rice canopy height

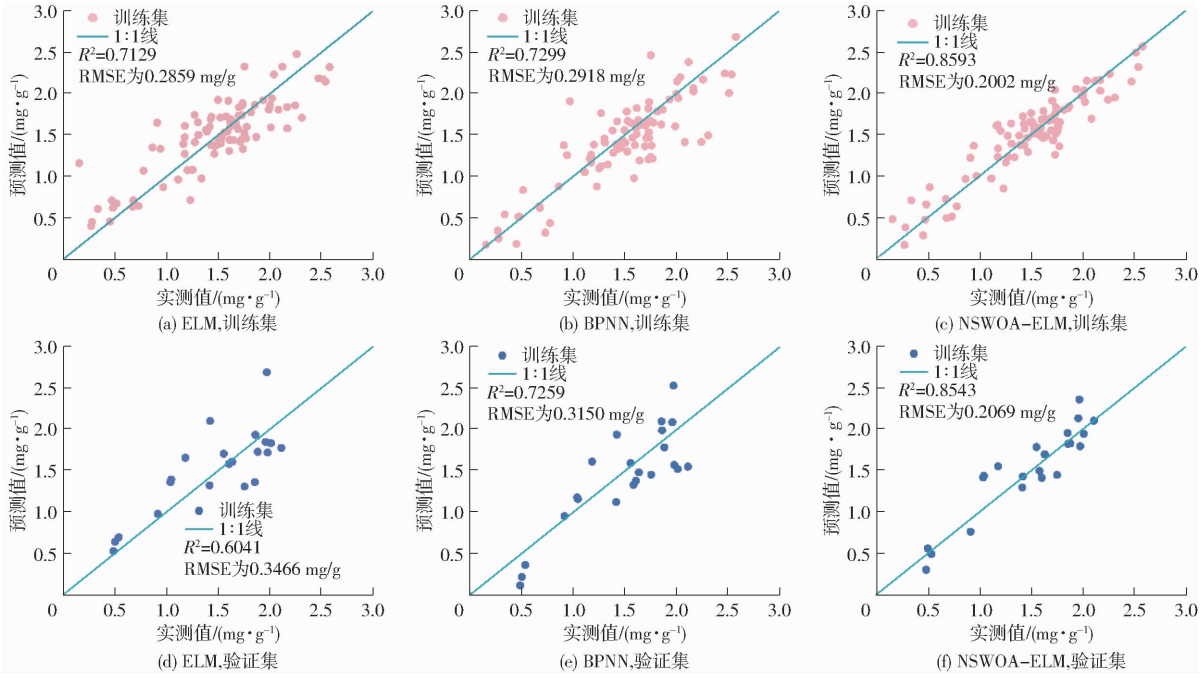


图 6　3 种水稻冠层氮素含量反演模型检测结果

Fig. 6　Three results of canopy nitrogen content inversion model in rice

在明显不足。对于 NSWOA－ELM 模型，设置初始种群数为 50，每个搜索代理的决策变量数量是 80，最大迭代次数为 50，结果显示：NSWOA－ELM 模型反演效果优于另外 2 种模型，氮素训练集和验证集决定系数 R^2 分别达到 0.859 3、0.854 3，RMSE 分别为 0.200 2、0.206 9 mg/g。综上所述，NSWOA－ELM 模型表现出较好的拟合度和较低的误差，因此更适用于水稻冠层氮素含量反演。

3　讨论

氮素是水稻生长发育过程中必不可少的元素之一[23]，利用高光谱技术实现水稻冠层氮素含量的无损检测是十分必要的。鉴于此，本文提出了一种结合连续投影算法（SPA）和多目标鲸鱼优化算法（NSWOA）优化的极限学习机（ELM）模型来预测水稻冠层氮素含量。试验结果表明，NSWOA－ELM 模型在预测精度和稳定性上明显优于 BP 神经网络和普通 ELM 模型，实现了利用水稻冠层高光谱数据对氮素浓度进行反演，展现出较高的潜力和应用价值。

针对高光谱数据维度较高且存在大量冗余信息的问题，采用 SPA 提取 400、440、487、542、589、660、675、739、766、808、878、912、949 nm 13 个波长。其中，波长 400～750 nm 范围内的可见光区域受叶片的色素吸收特性影响，与叶绿素含量密切相关，由于氮素是叶绿素的重要组成部分，所以在可见光范围内的光谱，可以反映出部分氮素水平[24]。波长 750 nm 以上的近红外波段的反射率能反映叶片的结构特性和生理状态，这些特性间受到氮素含量的影响[25]。因此，这些波长在氮素检测中具有显著的光谱响应，能够有效反映氮素含量变化，从而降低数据维度和计算时间，为模型构建提供了支持。

ELM 模型与传统的 BP 神经网络不同，BP 模型

随机初始化权重和阈值,导致模型容易陷入局部最优且训练耗时较长。而 ELM 模型相比 BP 神经网络,训练速度更快,推广性能更佳。多目标鲸鱼优化算法全局搜索能力强、收敛速度快,通过初始化鲸鱼群体并随机生成搜索代理的位置,而后通过适应度评估对每个代理进行非支配排序,确保能够找到最优解,而在位置更新的过程中,该算法模拟了自然界中座头鲸的包围和螺旋搜索行为,有效提升了模型的泛化能力,避免了局部最优问题。NSWOA - ELM 模型通过优化 ELM 参数选择,在决定系数(R^2)和均方根误差(RMSE)方面相较于传统 BP 神经网络和普通 ELM 模型均表现出更优异的性能。这对于实时、无损、准确地检测水稻冠层中的氮素含量具有重要意义。

为更全面地验证模型鲁棒性,将模型分为分蘖期、拔节期、孕穗期和抽穗期 4 个不同的生育阶段进行讨论,并对这些模型反演精度进行对比,实验结果如图 7 所示。结果表明,不同生育期的反演效果存在显著差异,其中,NSWOA - ELM 模型在所有生长阶段均表现出较好的反演效果,尤其是在抽穗期,其反演精度明显优于其他时期,可能是由于此时水稻叶片氮素含量趋于稳定,且叶片的光谱特征与氮素含量的关系较为明确[26]。相比之下,孕穗期反演精度较差,这可能是因为此时期水稻对温度的敏感性较高,温度波动可能导致叶片生理活动的不稳定,反演效果受到一定影响[27]。此外,分蘖期和拔节期反演效果处于中等水平。

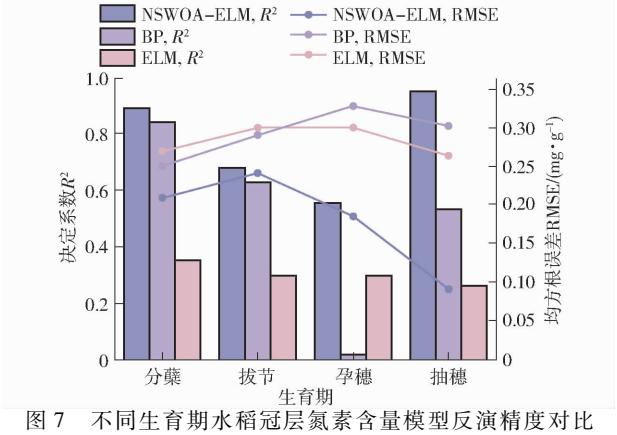


图 7 不同生育期水稻冠层氮素含量模型反演精度对比

Fig. 7 Comparison of inversion accuracy of rice canopy nitrogen content models at different growth stages

针对不同氮素水平对反演效果的影响,将氮素含量划分为低氮(0 ~ 1 mg/g)、中氮(1 ~ 2 mg/g)和高氮(2 ~ 3 mg/g)3 个层次,并对其结果进行分析。试验结果如图 8 所示,可以看出,3 种模型均在低氮水平下反演效果最佳。这可能是因为在低氮条件下,作物叶片中的氮素含量较为均匀,光谱信号与氮素含量之间呈线性关系,模型能够更精准地捕捉这一变化[28]。随着氮素含量增加,水稻光合作用可能受到抑制,导致光谱信号的变化不再单纯与氮素含量成正比[29]。在中高氮水平下,可能导致叶片结构的改变,如叶片老化或营养失衡,进一步影响冠层光谱反射特征[30]。此外,高氮水平可能导致水稻生理调节机制发生变化,例如增加叶肉细胞壁表面积同时减少细胞壁厚度,从而影响叶肉导度对环境因子的响应[31]。这些变化可能导致叶片氮素分布不均匀,进而增加光谱信号复杂性,使得反演模型难以准确捕捉氮素含量与光谱反射率之间的关系,最终导致反演精度下降。

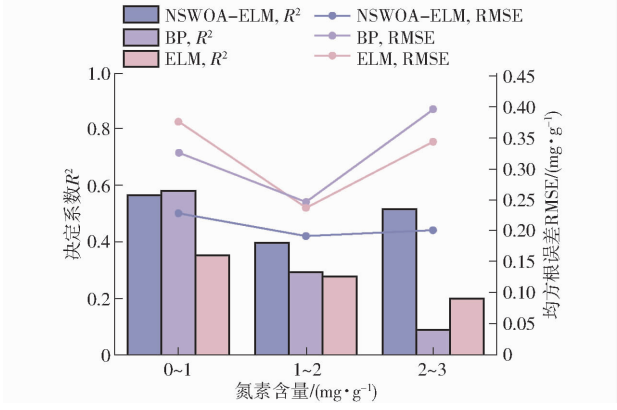


图 8 不同氮素水平水稻冠层氮素含量模型反演精度对比

Fig. 8 Comparison of inversion accuracy of rice canopy nitrogen content models with different nitrogen levels

尽管 NSWOA - ELM 模型整体表现出色,但仍存在可改进之处。首先,虽然 SPA 在特征波长选择中表现优异,但在不同环境条件和不同品种的水稻中,特征波长的选择可能存在变化。未来研究可以引入更多样本数据,或尝试将 SPA 与其他算法如竞争性自适应重加权算法(CARS)相结合进行特征选择。除此之外,可以通过引入其他优化算法或集成学习方法进一步提升模型的鲁棒性和适应性。

综上所述,本文提出的基于 NSWOA - ELM 的水稻冠层氮素含量反演模型在预测能力和稳定性方面表现出显著优势,为描述水稻生长状况和实现田间精准施肥提供了理论依据和技术支持。然而,本研究仍存在一定不足之处,未来仍需要在更多应用场景中进行验证,并结合其他优化算法及多种数据来源,以进一步提高模型的通用性和准确性。

4 结论

(1)利用高光谱技术对水稻冠层氮素含量进行了预测。首先对水稻冠层原始光谱进行 SG 平滑预处理。对于预处理后的光谱通过连续投影算法

(SPA)提取水稻冠层高光谱数据的特征波长，选取特征波长作为模型输入，氮素数据作为模型输出，分别构建了 BP 神经网络(BPNN)、极限学习机(ELM)以及多目标鲸鱼算法优化的极限学习机(NSWOA－ELM)3 种模型，并对其结果进行了比较分析。

(2)针对高光谱数据，使用连续投影算法提取 400～1 000 nm 范围的冠层高光谱反射率数据，筛选的特征波长为 400、440、487、542、589、660、675、739、766、808、878、912、949 nm，这些波长用于构建氮素反演模型。

(3)在全生育期内，NSWOA－ELM 模型表现出优异的性能，其训练集和验证集决定系数 R^2 为 0.859 3 和 0.854 3，RMSE 为 0.200 2 mg/g 和 0.206 9 mg/g。NSWOA－ELM 模型相较于 BPNN 模型和 ELM 模型，在水稻各个生育期的冠层氮素含量估测上均展现出明显的优势。同时，NSWOA－ELM 模型在针对不同层次氮素含量的估测上也大体表现得更为优越。

参　考　文　献

[1] 文孝荣，康民泰，唐福森，等. 不同施氮量对新稻 36 号产量及碾米品质的影响[J]. 北方水稻，2024，54(3)：11－14.
WEN Xiaorong, KANG Mintai, TANG Fusen, et al. Effects of different nitrogen application rates on yield and milling quality of Xindao－36[J]. Northern Rice, 2024, 54(3): 11－14. (in Chinese)

[2] 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 images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(2): 178－187. (in Chinese)

[3] 许童羽，金忠煜，郭忠辉，等. 基于 CARS－RUN－ELM 算法的水稻叶片氮磷含量协同反演方法[J]. 农业工程学报，2022，38(10)：148－155.
XU Tongyu, JIN Zhongyu, GUO Zhonghui, et al. Simultaneous inversion method of nitrogen and phosphorus contents in rice leaves using CARS－RUN－ELM algorithm[J]. Transactions of the CSAE, 2022, 38(10): 148－155. (in Chinese)

[4] 许童羽，杨佳欣，白驹驰，等. 基于无人机偏振遥感的水稻冠层氮素含量反演模型[J]. 农业机械学报，2023，54(10)：171－178.
XU Tongyu, YANG Jiaxin, BAI Juchi, et al. Inversion model of nitrogen content of rice canopy based on UAV polarimetric remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 171－178. (in Chinese)

[5] SHANC, MA H, YIN W. Hyperspectral imaging and deep learning for precision agriculture: applications, opportunities, and challenges[J]. IEEE Access, 2021, 9: 122556－122573.

[6] 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)

[7] LIU L, WANG J, HUANG W, et al. Monitoring crop nitrogen status with hyperspectral remote sensing[J]. Journal of Applied Remote Sensing, 2019, 13(3): 034517.

[8] SINGH P, PANDEY P C, PETROPOULOS G P, et al. Hyperspectral remote sensing in precision agriculture: present status, challenges, and future trends[M]Hyperspectral Remote Sensing. Elsevier, 2020: 121－146.

[9] 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 inverting nitrogen content in canopy leaves of japonica rice in Northeastern China based on hyperspectral remote sensing of unmanned aerial vehicles[J]. Spectroscopy and Spectral Analysis, 2019, 39(10): 3281－3287. (in Chinese)

[10] CAO Y, JIANG K, WU J, et al. Inversion modeling of japonica rice canopy chlorophyll content with UAV hyperspectral remote sensing[J]. PLoS ONE, 2020, 15(9): e0238530.

[11] ZHANG Juanjuan, CHENG Tao, SHI Lei, et al. Combining spectral and texture features of UAV hyperspectral images for leaf nitrogen content monitoring in winter wheat[J]. International Journal of Remote Sensing, 2022, 43(7): 2335－2356.

[12] 张国圣，许童羽，于丰华，等. 基于高光谱的水稻叶片氮素估测与反演模型[J]. 浙江农业学报，2017，29(5)：845－849.
ZHANG Guosheng, XU Tongyu, YU Fenghua, et al. Nitrogen content inversion of rice leaf based on the hyperspectral data[J]. Acta Agriculturae Zhejiangensis, 2017, 29(5): 845－849. (in Chinese)

[13] 许童羽，邢思敏，于丰华，等. 基于多植被指数组合的 BAS－ELM 粳稻冠层氮含量反演方法[J]. 沈阳农业大学学报，2021，52(5)：577－585.
XU Tongyu, XING Simin, YU Fenghua, et al. A BAS－ELM inversion method of japonica rice canopy nitrogen content based on a combination of multiple vegetation indices[J]. Journal of Shenyang Agricultural University, 2021, 52(5): 577－585. (in Chinese)

[14] 聂素云，杨彬，夏微，等. 冬小麦多时期冠层含水量遗传优化遥感反演[J]. 华东师范大学学报(自然科学版)，2023(3)：71－81.
NIE Suyun, YANG Bin, XIA Wei, et al. Remote sensing inversion of multi-period winter wheat canopy water content based on

a genetic algorithm[J]. Journal of East China Normal University (Natural Science), 2023(3): 71 - 81. (in Chinese)

[15] ZHANG J, ZHU J, YANG L, et al. Mapping of the waxy gene in *Brassica Napus* L. via bulked segregant analysis (BSA) and whole-genome resequencing[J]. Agronomy, 2023, 13(10): 2611.

[16] DENG Y, ZHOU X, SHEN J, et al. New methods based on back propagation(BP) and radial basis function(RBF) artificial neural networks(ANNs) for predicting the occurrence of haloketones in tap water[J]. Science of The Total Environment, 2021, 772: 145534.

[17] LIU L. Research on water environment monitoring based on the internet of things combined with neural network[J]. Optical Memory and Neural Networks, 2021, 30(3): 206 - 213.

[18] 许童羽,郭忠辉,于丰华,等. 采用 GA - ELM 的寒地水稻缺氮量诊断方法[J]. 农业工程学报,2020,36(2):209 - 218.
XU Tongyu, GUO Zhonghui, YU Fenghua, et al. Genetic algorithm combined with extreme learning machine to diagnose nitrogen deficiency in rice in cold region[J]. Transactions of the CSAE, 2020, 36(2): 209 - 218. (in Chinese)

[19] 陈媛媛,王志斌,王召巴,等. 区间极限学习机结合遗传算法用于红外光谱气体浓度反演的研究[J]. 光谱学与光谱分析,2014,34(5):1244 - 1248.
CHEN Yuanyuan, WANG Zhibin, WANG Zhaoba, et al. Research on concentration retrieval of gas from ftir spectra by interval extreme learning machine and genetic algorithm[J]. Spectroscopy and Spectral Analysis, 2014, 34(5): 1244 - 1248. (in Chinese)

[20] 陆军胜,陈绍民,黄文敏,等. 采用 SEPLS_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 SEPLS_ELM model[J]. Transactions of the CSAE, 2021, 37(18): 128 - 135. (in Chinese)

[21] GUO L, SUN X R, FU P, et al. Mapping soil organic carbon stock by hyperspectral and time-series multispectral remote sensing images in low-relief agricultural areas[J]. Geoderma, 2021, 398: 115118.

[22] JANGIR P, JANGIR N. Non-dominated sorting whale optimization algorithm (NSWOA): a multi-objective optimization algorithm for solving engineering design problems[J]. Global Journal of Research in Engineering, 2017, 17: 15 - 42.

[23] 霍中洋,张洪程,王秀芹,等. 氮肥对亚种间杂交水稻“两优培九”产量及氮素营养特性的影响[J]. 江苏农业学报,2003 (4):223 - 227.
HUO Zhongyang, ZHANG Hongcheng, WANG Xiuqin, et al. Effects of nitrogen fertilizer on yield and nitrogen nutrition characteris-tic for intersubspecific hybrid rice “Liangyoupeijiu”[J]. Jiangsu Journal of Agricultural Sciences, 2003, (4): 223 - 227. (in Chinese)

[24] 王楠,陈春玲,相爽,等. 基于叶片双层辐射传输机理的水稻叶绿素含量反演[J]. 农业工程学报,2024,40(17):171 - 178.
WANG Nan, CHEN Chunling, XIANG Shuang, et al. Inversing chlorophyll contents in rice using radiation transport of leaf bilayer[J]. Transactions of the CSAE, 2024, 40(17): 171 - 178. (in Chinese)

[25] SLATON M R, E Raymodn Hunt JR. E, SMITH W K. Estimating near-infrared leaf reflectance from leaf structural characteristics[J]. American Journal of Botany, 2001, 88(2): 278 - 284.

[26] 陈春玲,周长献,于丰华,等. 基于光谱特征参数的粳稻冠层氮素含量反演方法[J]. 沈阳农业大学学报,2020,51(2): 218 - 224.
CHEN Chunling, ZHOU Changxian, YU Fenghua, et al. A study on inversion method of nitrogen content in japonica rice based on spectral characteristic parameters[J]. Journal of Shenyang Agricultural University, 2020, 51(2): 218 - 224. (in Chinese)

[27] 李健陵,霍治国,吴丽姬,等. 孕穗期低温对水稻产量的影响及其生理机制[J]. 中国水稻科学,2014,28(3):277 - 288.
LI Jianling, HUO Zhiguo, WU Liji, et al. Effects of low temperature on grain yield of rice and its physiological mechanism at the booting stage[J]. Chinese Journal of Rice Science, 2014, 28(3): 277 - 288. (in Chinese)

[28] 由明明. 基于高光谱参数的冬油菜理化参量估算模型研究[D]. 杨凌:西北农林科技大学,2018.
YOU Mingming. Estimation models of physicochemical parameters of winter rape based on hyperspectral parameters[D]. Yangling: Northwest A&F University, 2018. (in Chinese)

[29] 李勇. 氮素营养对水稻光合作用与光合氮素利用率的影响机制研究[D]. 南京:南京农业大学,2011.
LI Yong. Studies on Mechanisms of the effects of different nitrogen supplies on photosynthetic nitrogen use efficiency of rice plants[D]. Nanjing: Nanjing Agricultural University, 2011. (in Chinese)

[30] ADO S Z. Relationship of leaf senescence with ROS generation and NSC translocation in rice (*Oryza sativa* L.) leaf sheath as affected by N supply[D]. Hangzhou: Zhejiang University, 2019.

[31] XIONG D, LIU X, LIU L, et al. Rapid responses of mesophyll conductance to changes of CO_2 concentration, temperature and irradiance are affected by N supplements in rice[J]. Plant Cell and Environment, 2015, 38: 2541 - 2550.