DOI: 10.12398/j.issn.2096-7217.2024.03.002

基于BWO-ELM的水稻氮素无人机高光谱反演研究

李世隆[1,2], 许辰一[1,2], 王楠[1,2], 曹慧妮[1,2], 于丰华[1,2,3*]

(1. 沈阳农业大学信息与电气工程学院,辽宁沈阳,110866; 2. 国家数字农业区域创新分中心(东北),辽宁沈阳,110866; 3. 辽宁省智慧农业技术重点实验室,辽宁沈阳,110866)

摘要:氮素是水稻生长发育的重要元素之一,精准估测氮素浓度对指导水稻精准施肥、辅助氮高效品种选育是十分重要的。传统田间采样方式难以实时获取水稻氮素浓度,随着信息技术的快速发展,目前通过机器学习方法建立无人机高光谱数据与氮素浓度的关系,是作物氮素营养诊断的主要技术路线之一。研究以连续投影算法筛选的无人机冠层高光谱数据特征波段为输入,实测氮素浓度数据为输出构建反演模型。极限学习机(ELM)与同类型的机器学习方法相比,具有速度快、泛化能力强的优势,但由于其随机生成的连接权重和神经元阈值,导致其训练稳定性存在不足,且容易陷入局部最优解。白鲸优化算法(BWO)是一种以白鲸行为为灵感而设计的求解单模态和多模态优化问题的竞争算法,本研究通过白鲸优化算法对极限学习机的输入层与隐含层之间的连接权重、隐含层初始权重进行优化,构建BWO-ELM水稻氮素浓度无人机高光谱反演模型,实现对水稻氮素浓度的快速估测。研究结果表明:连续投影算法筛选出特征波段10个,分别为673、703、727、823、850、877、895、952、961和985 nm。基于BWO-ELM构建的氮素浓度反演模型训练集R^2与*RMSE*分别为0.742 5、0.382 6%,测试集R^2与*RMSE*分别为0.702 8、0.487 7%。预测能力优于基于ELM构建的氮素浓度反演模型。综上所述,基于BWO-ELM的水稻氮素浓度无人机高光谱反演模型可以快速准确获取水稻氮素浓度,为水稻营养监测提供新的方法。

关键词:白鲸优化算法;极限学习机;氮素;无人机;高光谱;水稻

中图分类号:S24 **文献标识码:**A **文章编号:**2096-7217(2024)03-0014-08

李世隆, 许辰一, 王楠, 曹慧妮, 于丰华. 基于BWO-ELM的水稻氮素无人机高光谱反演研究[J]. 智能化农业装备学报(中英文), 2024, 5(3): 14-21

LI Shilong, XU Chenyi, WANG Nan, CAO Huini, YU Fenghua. Research on rice nitrogen unmanned aerial vehicle hyperspectral inversion based on BWO-ELM [J]. Journal of Intelligent Agricultural Mechanization, 2024, 5(3): 14-21

0 引言

氮素是水稻生长发育过程中不可或缺的元素之一[1]。氮素供应不足,会导致水稻的生长速度明显减慢,影响植株的生长和发育,降低水稻的产量和品质。通过田间采样方式获取水稻氮素数据成本高、时间长[2],且结果具有滞后性,难以及时对田间管理进行指导。近年来,随着技术的快速发展,利用无人机高光谱技术估测水稻氮素浓度,监测作物长势,是当前数字农业领域研究热点之一[3]。

基于无人机高光谱技术估测水稻氮素浓度,具有快速、无损、准确等特点,目前已取得一定的研究成果。其中通过机器学习方法,建立高光谱反射率与氮素含量间的统计模型,是反演水稻氮素浓度最常用的方法之一[4-6]。杨红云等[7]通过便携式地物波谱仪获取水稻分蘖期顶三叶光谱数据,分别对光谱采用三种方法进行预处理、两种方法进行降维,并采用支持向量机构建水稻氮素营养诊断模型,实现对水稻氮素快速准确地诊断。王娇娇等[8]通过相关性分析和高斯过程回归等方法,筛选所获取的水稻全生育期的叶片和冠层尺度的高光谱反射率的氮素敏感波段,利用多种机器学习方法构建氮素监测模型。

极限学习机(extreme learning machine, ELM)与同类型的机器学习方法相比,具有速度快[9]、泛化能力

收稿日期:2024-05-15 修回日期:2024-07-20

基金项目:国家自然科学基金青年项目(32201652);辽宁省自然科学基金面上项目(2023-MSLH-283);辽宁省"兴辽英才计划"项目(XLYC2203005)

第一作者:李世隆,男,2000年生,山东平度人,硕士研究生;研究方向为精准农业航空。E-mail: lishilong0725@163.com

*通信作者:于丰华,男,1989年生,吉林白山人,博士,教授;研究方向为精准农业航空。E-mail: adan@syau.edu.cn

强[10]的优势，目前被广泛应用于构建氮素反演模型。SAHOO等[11]通过田间便携式光谱仪和无人机成像光谱仪获取光谱数据，通过多种方法预测小麦叶片氮含量，结果表明基于ELM构建的反演模型预测效果最好。极限学习机的输入量与隐含层的连接权值、隐含层神经元阈值具有随机性，影响所建立模型的稳定性和泛化能力，通过参数优化算法对极限学习机进行优化是一种常见的解决手段。YANG等[12]通过粒子群优化（PSO）算法获得极限学习机模型的优化输入权重和偏差值，以无人机平台获取的土壤高光谱图像为输入建立模型，对农田土壤有机质和土壤全氮进行预测。DEHGHANISANIJ等[13]通过榛子树搜索算法（HTS）对极限学习机进行优化，结合土壤数据、灌溉、肥料、气候和作物特性，以估算小麦产量和水分生产率。

元启发式算法[14]是随机算法与局部搜索算法相结合的产物，通过模拟自然界中的现象来搜索最优解。白鲸优化算法（beluga whale optimization，BWO）是一种受白鲸行为启发的元启发式算法，具有解决复杂优化问题的潜力。本研究通过连续投影算法（successive projections algorithm，SPA）对光谱的特征波段进行选择，并通过白鲸优化算法对极限学习机进行优化，构建水稻氮素浓度无人机高光谱反演模型，实现对氮素浓度的快速无损监测。

1　材料与方法

1.1　研究区域概况

试验区域位于中国辽宁省鞍山市海城市耿庄镇沈阳农业大学海城实训基地试验田（北纬40°58'45"，东经122°43'35"）。试验区域为暖温带季风气候区，四季分明、雨量充沛，全境气候温和，年平均气温10.4 ℃，年平均降水量721.3 mm，土地肥沃，为水稻生长提供了良好的自然条件。试验于2023年6—9月进行，种植的水稻品种为“沈农9816”。试验小区分布如图1所示，其中1～11号小区每个小区面积为660 m²；12～26号小区每个小区面积为40 m²。所有试验小区的田间管理策略是一致的。田间采样时间为水稻分蘖期至抽穗期，共采集了131组无人机冠层高光谱反射率及对应的氮素浓度数据。

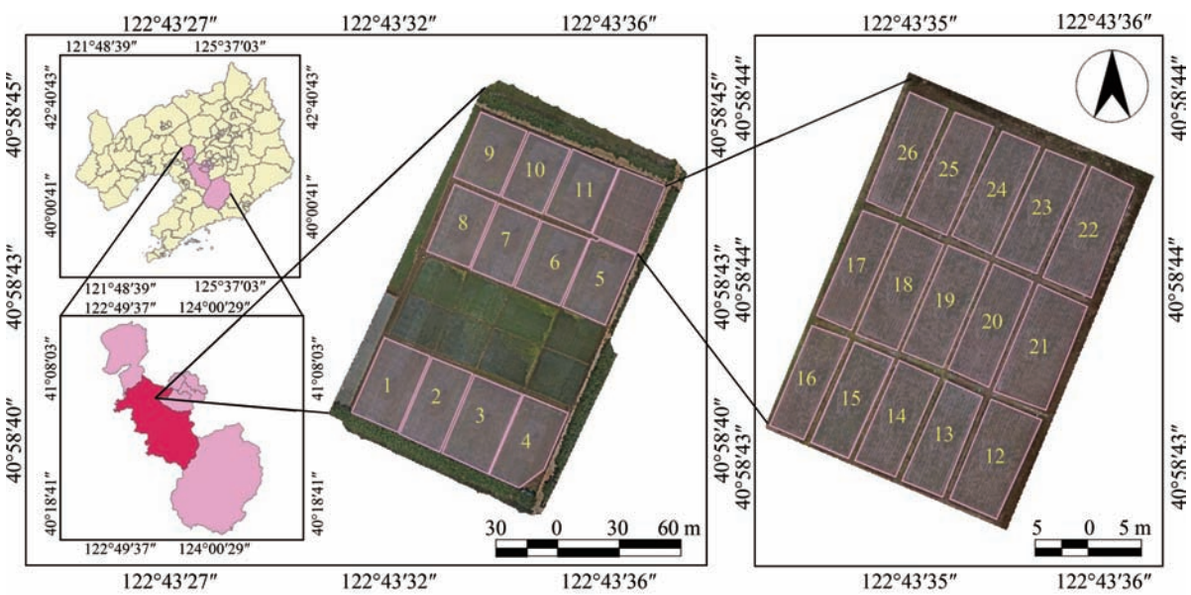


图1　试验区域概况

Figure 1　Overview of the experimental area

1.2　数据获取

1.2.1　水稻无人机高光谱数据获取

本研究采用M600 PRO六旋翼无人机作为飞行平台，高光谱成像仪选用GaiaSky-mini内置推扫式机载高光谱成像系统，高光谱的波段范围400～1 000 nm，分辨率3.5 nm，有效波段数为170个，单幅影像获取时间为15 s，帧速为162帧/s，无人机飞行高度为100 m，空间分辨率为7 cm。本研究将无人机高光谱数据采集时间选择在12:00—14:00之间，起飞前对高光谱成像仪进行暗电流校正及白板校正。同时在每景高光谱采集区域内放置一块1.5 m×1.5 m、反射率为60%的漫反射板，用于后期的反射数据校正。利用机载高光谱成像仪配套的SpectraVIEW软件对所获取的无人机高光谱遥感影像进行镜头、均匀性、反射率等预处理，最终获得水稻冠层高光谱反射率影像。无人机高光谱数据受环境因素影响产生噪声波段，直接使用原始光谱数据构建反演模型会降低氮素预估精度，本研究通过Savitzky-Golay卷积平滑算法处理原始光谱，可以在降噪的同时较好的

保留光谱原始信息。

1.2.2 水稻氮素浓度测定

为实现对水稻氮素浓度的测定,对各试验小区采样点进行破坏性采样。将样本放入烘箱中以105 ℃杀青30 min后,以80 ℃烘干至恒重。测量样本干物质量后将烘干后样本磨碎,对研磨后样本采用凯氏定氮法检测水稻氮浓度。凯氏定氮法[15]具体步骤如下:首先用天平称取0.2 g的样本,然后加入100 mL的浓硫酸溶液混合,静置4 h后加入2~3 mL的双氧水溶液,加热10 min后继续滴入双氧水直至溶液呈透明状态;之后将加入浓度为2%的硼酸溶液和氢氧化钠溶液并进行蒸馏处理,最后采用0.02 mol/L的硫酸溶液对样本溶液进行滴定,直至溶液变成酒红色为止。其计算公式如式(1)所示。

$$N=\frac{(v_1-v_0)\times N_s\times 0.014}{w}\times 100\% \tag{1}$$

式中:N——水稻氮浓度,%;

v_0——空白试验中硫酸溶液体积,mL;

v_1——样品中硫酸溶液体积,mL;

N_s——硫酸溶液浓度,%;

w——样品质量,g。

1.3 水稻无人机冠层高光谱反射率特征波段选择

由于采集到的无人机冠层高光谱波段维度较高,存在大量冗余信息[16]。直接利用原始数据构建水稻氮素浓度反演模型会显著增加模型的运算时间,降低模型的反演精度。本研究利用连续投影算法[17](successive projections algorithm,SPA)对水稻冠层光谱反射率数据进行特征提取,将提取后的特征波段光谱反射率与对应氮素构成“光谱-氮素”数据集,并随机分为7:3用作反演模型的训练集和测试集。其中提取后的特征波段光谱反射率作为后续构建反演模型的输入数据,氮素浓度作为反演模型的输出数据。

1.4 基于BWO-ELM的水稻氮素浓度反演模型

极限学习机(extreme learning machine,ELM)是HUANG等[18]提出的一种机器学习方法,与浅层学习系统相比,ELM的学习能力和泛化能力更具优势[19]。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重和隐含层神经元的阈值都是随机生成的,在训练稳定性上存在不足,且容易陷入局部最优解[20-21]。

白鲸优化算法(beluga whale optimization,BWO)是ZHONG等[22]以白鲸游泳、捕猎、鲸落等行为为灵感设计的一种求解单模态和多模态优化问题的竞争算法。该算法主要包括探索、开发、鲸落3个阶段。BWO算法根据平衡因子B_f,来实现种群从探索到开发的过渡,其计算公式如式(2)所示。

$$B_f=B_0\left(1-\frac{T}{2T_{max}}\right) \tag{2}$$

式中:T——当前迭代次数;

T_{max}——总的迭代次数;

B_0——1个(0,1)范围内的随机值,在每次迭代中都会改变。

当平衡因子$B_f>0.5$时,进入探索阶段;当平衡因子$B_f\leqslant 0.5$时,进入开发阶段。随着迭代次数T的增加,B_f的波动范围从(0,1)减小到(0,0.5),说明开发阶段和探索阶段的概率发生了显著变化,开发阶段的概率是随着迭代次数的增加而逐渐变大的。

本研究采用白鲸优化(BWO)算法对极限学习机(ELM)的输入层与隐含层之间的连接权重、隐含层初始权重进行优化,构建基于BWO-ELM的水稻氮素浓度反演模型,其基本步骤如图2所示。白鲸优化算法输出的最优适应度位置是ELM连接权重和初始权重的阈值。并与在相同训练集和测试集下构建的基于ELM的水稻氮素浓度反演模型进行对比。

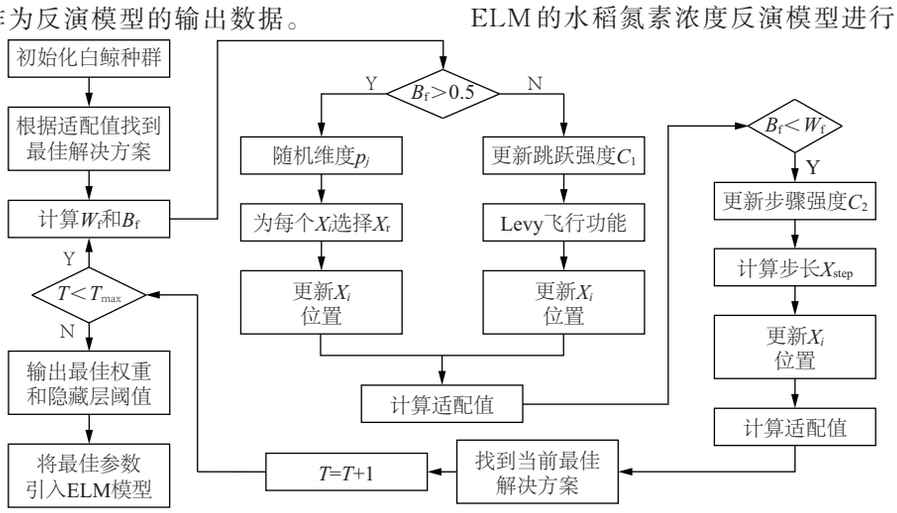


图2 基于白鲸算法优化的极限学习机

Figure 2 Extreme learning machine optimization based on moby dick algorithm

1.5　水稻氮素浓度反演模型评价方法

对于水稻氮素浓度反演模型反演结果，本研究通过决定系数R^2与均方根误差(root mean square error，*RMSE*)来判断反演精度。R^2主要用来描述两个变量之间的线性关系，通常用于判断回归模型的拟合程度。它介于0和1之间，R^2数值越高，残差平方和越小，拟合程度越好。是用来衡量观测值同真值之间的偏差，计算方法如式(3)所示。

$$R^2=\frac{ESS}{TSS}=1-\frac{RSS}{TSS}=\frac{\sum_{j=1}^{n}\left(X_{\mathrm{pred},j}-\overline{X_{\mathrm{meas}}}\right)^2}{\sum_{j=1}^{n}\left(X_{\mathrm{meas},j}-\overline{X_{\mathrm{meas}}}\right)^2}$$

$$=1-\frac{\sum_{j=1}^{n}\left(X_{\mathrm{meas},j}-X_{\mathrm{pred},j}\right)^2}{\sum_{j=1}^{n}\left(X_{\mathrm{meas},j}-\overline{X_{\mathrm{meas}}}\right)^2} \tag{3}$$

式中：*TSS*——总体平方和；

ESS——回归平方和；

RSS——残差平方和；

X_{pred}——预测值；

X_{meas}——观测值；

$\overline{X_{\mathrm{meas}}}$——观测值的平均值；

n——样本数量。

*RMSE*用于衡量模型预测值与观测值之间的平均偏差程度，*RMSE*越小，模型回归效果越好。计算方法如式(4)所示。

$$RMSE=\sqrt{\frac{\sum_{j=1}^{n}\left(X_{\mathrm{pred},j}-X_{\mathrm{meas},j}\right)^2}{n}} \tag{4}$$

2　结果与分析

2.1　数据整理结果

2.1.1　光谱预处理结果

本研究利用Savitzky-Golay卷积平滑算法，对所获得的试验小区400～1 000 nm无人机冠层高光谱数据进行处理，增强光谱特征，减少噪声影响，处理后的水稻冠层高光谱曲线如图3所示。

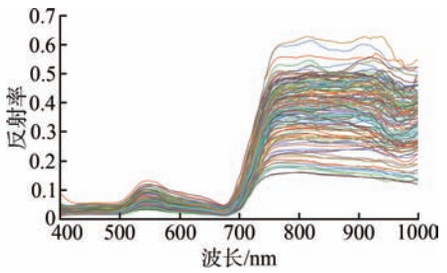


图3　高光谱信息平滑降噪处理

Figure 3　Smooth noise reduction processing of hyperspectral information

2.1.2　氮素浓度数据整理结果

采集到的水稻氮素浓度数据如表1所示，氮素浓度介于1.506%～4.956%之间。将其随机划分成两组，供反演模型的建立和模型验证。其中训练集样本数量92组，平均值为3.276%，标准差为0.734%；测试集样本数量39组，平均值为3.275%，标准差为0.788%。样本整体区分度较大，随机划分的两组数据集合理，可用于水稻氮素浓度反演建模。

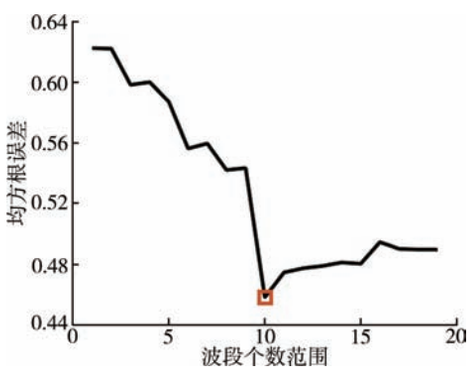
表1　水稻氮素浓度统计结果

Table 1　Statistical results of nitrogen concentration in rice

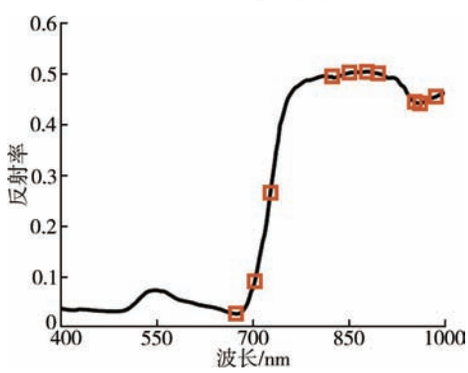
	样本数量	最大值	最小值	平均值	标准差
训练集	92	4.956	1.659	3.276	0.734
测试集	39	4.817	1.506	3.275	0.788

2.2　水稻冠层高光谱反射率特征波段选择结果

水稻冠层高光谱反射率特征波段选择结果如图4所示。



(a) SPA筛选波段数



(b) SPA波段提取结果

图4　水稻冠层高光谱反射率特征波段选择结果

Figure 4　Selection results of spectral bands for rice canopy hyperspectral reflectance characteristics

本研究采用SPA对水稻冠层高光谱数据进行特征选择，波段个数范围为5～20，并利用测试集对筛选波段进行内部交叉验证，根据验证结果的均方根误差筛选水稻生物量高光谱特征波段，*RMSE*最低值时即为最优子

集波长数据。结果如图4所示。利用SPA进行特征波段筛选时,随着筛选变量数的增加,*RMSE*整体呈下降趋势。*RMSE*取最低0.458 5时,提取到光谱特征波段10个,波长分别为673、703、727、823、850、877、895、952、961和985 nm。

2.3 基于BWO-ELM的水稻氮素浓度反演结果分析与评价

本研究以特征选择结果为输入,氮素浓度为输出,利用白鲸优化算法优化的极限学习机(BWO-ELM)构建无人机高光谱水稻氮素浓度反演模型,并与ELM构建的氮素浓度反演模型进行对比。

基于BWO-ELM的水稻氮素浓度反演结果如图5(a)和图5(b)所示,训练集和测试集的决定系数R^2与均方根误差*RMSE*具有较高的一致性,训练集R^2为0.742 5,*RMSE*为0.382 6%;测试集R^2为0.702 8,*RMSE*为0.487 7%。

相同数据集下,ELM的水稻氮素浓度反演结果如图5(c)和图5(d)所示,训练集R^2为0.520 5,*RMSE*为0.505 3%;测试集R^2为0.462,*RMSE*为0.608 3%。与之相比,BWO-ELM构建的模型测试集R^2提高了0.240 8,*RMSE*降低0.120 6%,预测精度有一定的提升,说明采用白鲸优化算法优化极限学习机在水稻氮素含量反演上具有一定的优势。

综上所述,两种方法构建的氮素浓度反演模型可靠性和估测能力具有一致性,基于BWO-ELM的水稻氮素浓度反演模型具有较高的可靠性。

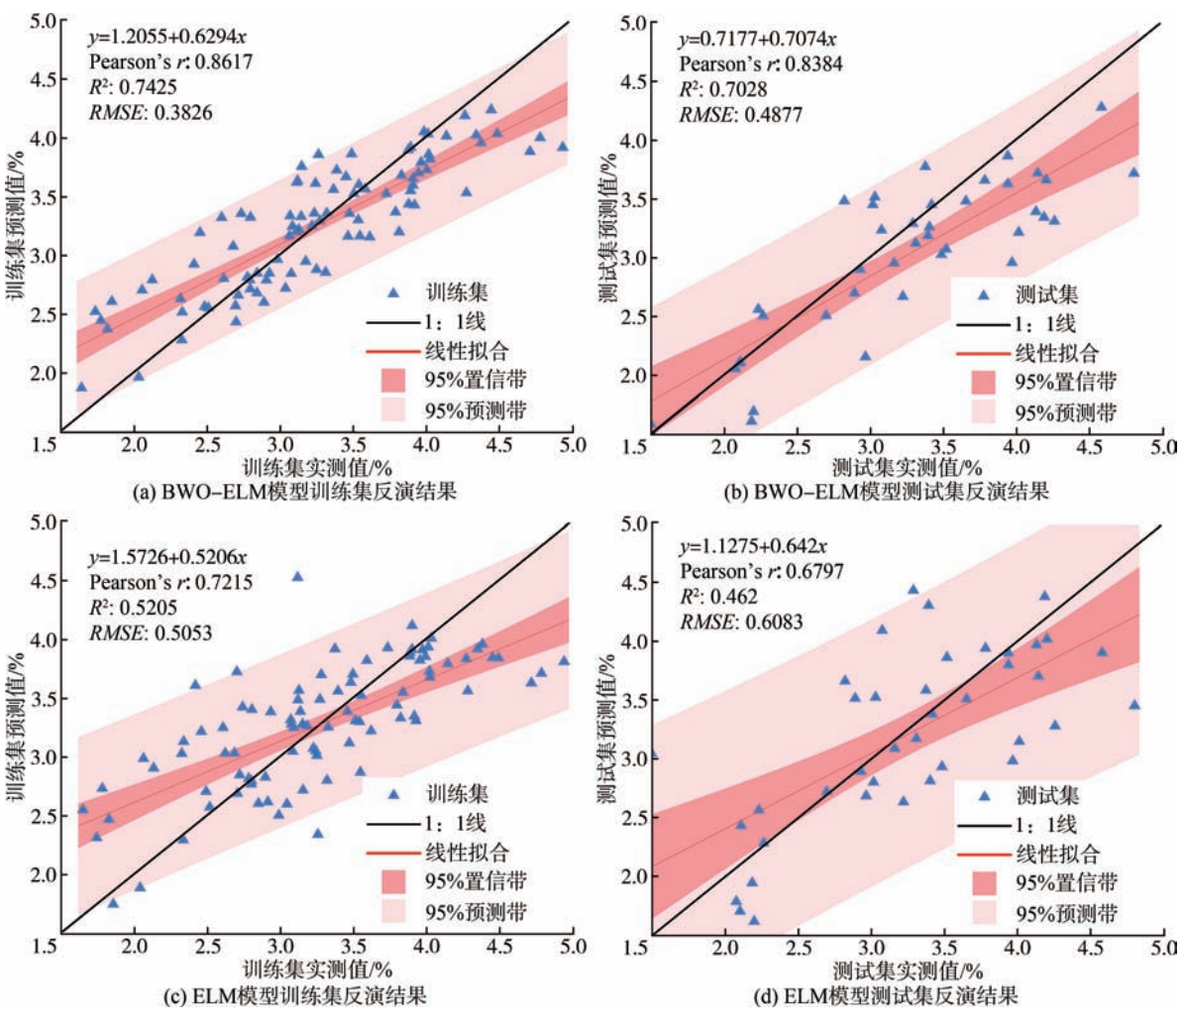


图5 水稻氮素浓度反演结果

Figure 5 Inversion results of nitrogen concentration in rice

3 讨论

本研究以白鲸优化算法优化的极限学习机构建水稻氮素浓度无人机高光谱反演模型,以实现水稻氮素精准估测,现对本研究相关结果进行讨论。

1)实测无人机冠层高光谱数据存在冗余信息,造成反演精度下降。本研究选用的两种方案反演氮素精度均较低,究其原因可能是实测数据存在误差。与旱田作物土壤背景相比,稻田浅水背景存在水体镜面反射、内部透射及散射等特有的光学特性[23],水体在可见

光和近红外波段吸收性较强，与土壤的光学特性完全不同[24]，浅水背景光学特性对水稻冠层高光谱的作用机理并不明确。有研究将应用于卫星遥感影像的高光谱混合像元解混，引入无人机高光谱数据处理过程，减少了水体混合部分对光谱数据的影响，获得更加准确的水稻无人机高光谱反射率[25]。

2)提取更合适的特征波段提升反演精度。针对所采集到的高光谱数据维度较高、存在大量冗余信息的问题，本研究通过连续投影算法提取高光谱数据的特征波段，降低模型运算时间。有研究表明竞争性自适应重加权算法(CARS)提取波段的建模效果优于连续投影算法[26]，但CARS筛选出的特征波段数量仍较多，会影响建模估算的效率。有研究耦合CARS和SPA，得到竞争性自适应重加权采样-连续投影算法(CARS-SPA)，筛选土壤有机碳含量特征波段，取得了较好的效果[27-28]。通过试验对比确定更适合反演水稻氮素的特征选择方法，是本研究下一步提高反演精度的研究方向之一。

3)寻找更合适的反演方法以提升氮素估测精度。本研究的结论表明，BWO-ELM模型反演效果优于ELM模型，说明通过参数优化算法优化极限学习机，可有效提升极限学习机预测能力。寻找更适合水稻氮素反演的参数优化算法、机器学习方法，是下一步研究提升反演模型预测能力的有效途径之一。

4　结论

本研究以2023年沈阳农业大学海城实训基地试验田种植的“沈农9816”为研究对象，利用白鲸优化(BWO)算法优化极限学习机(ELM)，通过连续投影算法(SPA)提取水稻无人机冠层高光谱数据的特征波段，选取了10个特征波段作为模型输入，氮素浓度作为模型输出，构建BWO-ELM水稻氮素浓度反演模型，以期利用无人机冠层高光谱实现对水稻氮素浓度快速反演。本研究有如下结论：

1)通过SPA算法提取波段范围为400～1 000 nm的无人机冠层高光谱数据，*RMSE*取最低0.458 5时，提取到光谱特征波段10个，波长分别为673、703、727、823、850、877、895、952、961和985 nm。

2)以特征波段选择结构为输入、氮素浓度为输出，构建基于BWO-ELM的水稻氮素浓度反演模型，其结果为训练集R^2为0.742 5、*RMSE*为0.382 6%，测试集R^2为0.702 8、*RMSE*为0.487 7%；基于ELM构建的水稻氮素浓度反演模型其结果为训练集R^2为0.520 5，*RMSE*为0.505 3%；测试集R^2为0.462，*RMSE*为0.608 3%。由结果可知，基于BWO-ELM构建的水稻氮素浓度反演模型，明显优于基于ELM构建的水稻氮素浓度反演模型。BWO-ELM模型展现了良好的预测能力，能够为水稻营养监测提供新的方法。

参　考　文　献

[1] 刘星，邓仕文，陈英龙，等. 水稻氮磷高效吸收与利用的特征及机制研究进展[J]. 江苏农业科学，2024，52(5)：1－11.
LIU Xing，DENG Shiwen，CHENG Yinglong，et al. Research progress on the characteristics and mechanisms of efficient absorption and utilization of nitrogen and phosphorus in rice [J]. Jiangsu Agricultural Sciences，2024，52(5)：1－11.

[2] 李艳大，舒时富，陈立才，等. 基于便携式作物生长监测诊断仪的江西双季稻氮肥调控研究[J]. 农业工程学报，2019，35(2)：100－106.
LI Yanda，SHU Shifu，CHEN Licai，et al. Regulation of nitrogen fertilizer based on portable apparatus for crop growth monitoring and diagnosis in Jiangxi double cropping rice [J]. Transactions of the Chinese Society of Agricultural Engineering，2019，35(2)：100－106.

[3] 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.

[4] TAN K，WANG S，SONG Y，et al. Estimating nitrogen status of rice canopy using hyperspectral reflectance combined with BPSO-SVR in cold region [J]. Chemometrics and Intelligent Laboratory Systems，2018，172：68－79.

[5] 张杰，徐波，冯海宽，等. 基于集成学习的水稻氮素营养及籽粒蛋白含量监测[J]. 光谱学与光谱分析，2022，42(6)：1956－1964.
ZHANG Jie，XU Bo，FENG Haikuan，et al. Monitoring nitrogen nutrition and grain protein content of rice based on ensemble learning [J]. Spectroscopy and Spectral Analysis，2022，42(6)：1956－1964.

[6] 李金敏，陈秀青，杨琦，等. 基于高光谱的水稻叶片氮含量估计的深度森林模型研究[J]. 作物学报，2021，47(7)：1342－1350.
LI Jinmin，CHEN Xiuqing，YANG Qi，et al. Deep learning models for estimation of paddy rice leaf nitrogen concentration based on canopy hyperspectral data [J]. Acta Agronomica Sinica，2021，47(7)：1342－1350.

[7] 杨红云，周琼，杨珺，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.

[8] 王娇娇, 宋晓宇, 梅新, 等. 基于高斯回归分析的水稻氮素敏感波段筛选及含量估算[J]. 光谱学与光谱分析, 2021, 41(6): 1722－1729.
WANG Jiaojiao, SONG Xiaoyu, MEI Xin, et al. Sensitive bands selection and nitrogen content monitoring of rice based on Gaussian regression analysis [J]. Spectroscopy and Spectral Analysis, 2021, 41(6): 1722－1729.

[9] 王椿晶, 王海瑞. 深度在线小波极限学习在旋转机械故障诊断中的应用[J]. 机械科学与技术, 2023, 42(7): 1029－1034.
WANG Chunjing, WANG Hairui. Application of depth online wavelet extreme learning machine in rotating machinery fault diagnosis [J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(7): 1029－1034.

[10] 谢国民, 刘东阳, 刘明. 多策略改进MPA算法与HKELM的变压器故障辨识[J]. 电子测量与仪器学报, 2023, 37(4): 172－182.
XIE Guomin, LIU Dongyang, LIU Ming. Transformer fault identification based on multi-strategy improved MPA algorithm and HKELM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 172－182.

[11] Sahoo R N, Gakhar S, Rejith R G, et al. Unmanned aerial vehicle (UAV) - based imaging spectroscopy for predicting wheat leaf nitrogen [J]. Photogrammetric Engineering & Remote Sensing, 2023, 89(2): 107－116.

[12] YANG X, BAO N, LI W, et al. Soil nutrient estimation and mapping in farmland based on UAV imaging spectrometry [J]. Sensors, 2021, 21(11): 3919.

[13] DEHGHANISANIJ H, EMAMI S, REZAVERDINEJAD V, et al. Potential of the hazelnut tree search - ELM hybrid approach in estimating yield and water productivity [J]. Applied Water Science, 2023, 13(2): 61.

[14] ATALI G, PEHLIVAN İ, GÜREVIN B, et al. Chaos in metaheuristic based artificial intelligence algorithms: A short review [J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2021, 29(3): 1354－1367.

[15] Xie L, Zhao Y, Wang C, et al. A study on the simultaneous determination of nitrogen content and ^{15}N isotope abundance in plants using peak height intensities at m/z 28 and 29 [J]. Talanta, 2024, 275: 126078.

[16] 王鹏, 郭永刚, 关法春, 等. 作物水分高光谱遥感监测研究进展[J]. 农业与技术, 2024, 44(1): 38－44.

[17] SOARES S F C, GOMES A A, ARAUJO M C U, et al. The successive projections algorithm [J]. TrAC Trends in Analytical Chemistry, 2013, 42: 84－98.

[18] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1－3): 489－501.

[19] 张然, 柴志勇, 张婷, 等. 基于机器学习模型的洪水预报研究进展[J]. 水利水电技术(中英文), 2023, 54: 89－101.
ZHANG Ran, CHAI Zhiyong, ZHANG Ting, et al. Research progress of flood forecasting based on machine learning models [J]. Water Resources and Hydropower Engineering, 2023, 54: 89－101.

[20] 郑晓雨, 樊重俊. 基于全局搜索策略WOA优化ELM的RUL预测性维护[J]. 智能计算机与应用, 2024, 14(2): 144－149.
ZHENG Xiaoyu, FAN Chongjun. Predictive maintenance of RUL based on global search strategy WOA optimized ELM [J]. Intelligent Computer and Applications, 2024, 14(2): 144－149.

[21] 赵征, 王金, 周孜钰, 等. 基于ISSA-ELM的垃圾发电厂焚烧过程建模方法研究[J]. 动力工程学报, 2023, 43(12): 1649－1656.
ZHAO Zheng, WANG Jin, ZHOU Ziyu, et al. Research on modelling method of the incineration process in waste-to-energy power plant based on ISSA-ELM [J]. Journal of Chinese Society of Power Engineering, 2023, 43: 1649－1656.

[22] ZHONG C, LI G, MENG Z. Beluga whale optimization: A novel nature-inspired metaheuristic algorithm [J]. Knowledge-Based Systems, 2022, 251: 109215.

[23] YANG P. Exploring the interrelated effects of soil background, canopy structure and sun-observer geometry on canopy photochemical reflectance index [J]. Remote Sensing of Environment, 2022, 279: 113133.

[24] 王世瑞, 沈芳, 李仁虎, 等. 无人机高光谱影像水面耀光去除及信息重构方法研究[J]. 华东师范大学学报(自然科学版), 2024(1): 36－49.
WANG Shirui, SHEN Fang, LI Renhu, et al. Research on water surface glint removal and information reconstruction methods for unmanned aerial vehicle hyperspectral images [J]. Journal of East China Normal University(Natural Science), 2024(1): 36－49.

[25] 于丰华, 赵丹, 郭忠辉, 等. 水稻分蘖期无人机高光谱影像混合像元特征分析与分解[J]. 光谱学与光谱分析, 2022, 42(3): 947－953.
YU Fenghua, ZHAO Dan, GUO Zhonghui, et al. Characteristic analysis and decomposition of mixed pixels from UAV hyperspectral images in rice tillering stage [J]. Spectroscopy and Spectral Analysis, 2022, 42 (3): 947－953.

[26] 张伏, 张方圆, 崔夏华, 等. 高光谱成像结合PSO-SVM的银杏果种类鉴别[J]. 光谱学与光谱分析, 2024, 44(3): 859－864.

ZHANG Fu, ZHANG Fangyuan, CUI Xiahua, et al. Identification of ginkgo fruit species by hyperspectral image combined with PSO-SVM [J]. Spectroscopy and Spectral Analysis, 2024, 44(3): 859－864.

[27] 樊泳灼，李新国．湖滨绿洲棕漠土有机碳含量高光谱估算[J]. 江苏农业学报，2023，39(6)：1341－1348.
FAN Yongzhuo, LI Xinguo. Hyperspectral prediction of organic carbon content of brown desert soil in the lakeside oasis [J]. Jiangsu Journal of Agricultural Sciences, 2023, 39(6): 1341－1348.

[28] 聂鹏程，钱程，覃锐苗，等．天空地一体化信息感知与融合技术发展现状与趋势[J]. 智能化农业装备学报(中英文)，2023，4(2)：1－11.
NIE Pengcheng, QIAN Cheng, QIN Ruimiao, et al. Development status and trends of space-air-ground integrated information sensing and fusion technology [J]. Journal of Intelligent Agricultural Mechanization, 2023, 4(2): 1－11.

Research on rice nitrogen unmanned aerial vehicle hyperspectral inversion based on BWO-ELM

LI Shilong[1, 2], XU Chenyi[1, 2], WANG Nan[1, 2], CAO Huini[1, 2], YU Fenghua[1, 2, 3*]

(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*; 3. *Key Laboratory of Intelligent Agriculture in Liaoning Province, Shenyang* 110866, *China*)

Abstract: Nitrogen is one of the important elements for the growth and development of rice, and accurate estimation of nitrogen concentration is crucial for guiding precise fertilization and assisting in the selection of nitrogen efficient varieties in rice. Traditional field sampling methods make it difficult to obtain real-time nitrogen concentration in rice. With the rapid development of information technology, establishing the relationship between unmanned aerial vehicle hyperspectral data and nitrogen concentration through machine learning methods is currently one of the main technical routes for crop nitrogen nutrition diagnosis. This study constructs an inversion model by using the feature bands of unmanned aerial vehicle canopy hyperspectral data selected by the continuous projection algorithm as input and the measured nitrogen concentration data as output. Extreme learning machine (ELM) has the advantages of fast speed and strong generalization ability compared to similar machine learning methods. However, due to its randomly generated connection weights and neuron thresholds, its training stability is insufficient and it is prone to falling into local optima. The beluga whale optimization (BWO) is a competitive algorithm inspired the behavior of beluga whales to solve single modal and multimodal optimization problems. In this study, the BWO-ELM rice nitrogen concentration unmanned aerial vehicle hyperspectral inversion model was constructed to achieve rapid estimation of rice nitrogen concentration by optimizing the connection weight between the input layer and the hidden layer of the ELM, as well as the initial weight of the hidden layer through the BWO. The research results show that the continuous projection algorithm filters out 10 feature bands, which are 673, 703, 727, 823, 850, 877, 895, 952, 961, and 985 nm, respectively. The training set R^2 and *RMSE* of the nitrogen concentration inversion model constructed based on BWO-ELM are 0.742 5 and 0.382 6%, respectively, while the testing set R^2 and *RMSE* are 0.702 8 and 0.487 7%, respectively. The predictive ability is superior to that of the nitrogen concentration inversion model constructed based on ELM. In summary, the rice nitrogen concentration unmanned aerial vehicle hyperspectral inversion model based on BWO-ELM can quickly and accurately obtain rice nitrogen concentration, providing a new method for rice nutrition monitoring.

Keywords: beluga whale optimization; extreme learning machine; nitrogen; unmanned aerial vehicle; hyperspectral; rice