

基于 DWT - DE 变换和 AHA - ELM 算法的水稻叶片氮含量预测方法

刘潭^{1,2} 王雯琦¹ 李子默¹ 齐缘¹ 郭忠辉^{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. 辽宁省农业信息化工程技术研究中心, 沈阳 110866)

摘要: 为提供一种利用光谱数据对水稻氮素含量加以快速、无损、准确预测的方法, 本文以东北水稻为研究对象, 采集水稻3个生育期的高光谱数据, 结合室内化学实验, 为了提高氮素预测精度和模型可解释性, 建立水稻氮素含量反演模型。将获取的高光谱数据和相对应的水稻叶片氮素含量, 首先通过低通滤波方法对光谱数据进行预处理, 针对处理后光谱数据, 采用耦合离散小波和一阶微分变换(DWT-DE变换)对光谱数据进行降维, 并分别与主成分分析(PCA)、离散小波多尺度分解方法进行对比。以降维后的结果作为输入, 实测叶片氮素含量为输出, 分别建立极限学习机(ELM)、粒子群优化支持向量机(PSO-SVM)和人工蜂鸟算法优化的极限学习机(AHA-ELM)反演模型, 对水稻叶片氮素含量进行预测和验证。结果表明, 采用耦合离散小波和一阶微分变换结果建立的AHA-ELM模型预测精度最高, 预测效果优于ELM和PSO-SVM模型, 训练集决定系数 R^2 为0.8064, RMSE为0.3251 mg/g, 验证集 R^2 为0.7915, RMSE为0.3620 mg/g。鉴于此, 本文提出的经DWT-DE变换建立的AHA-ELM模型在快速检测水稻氮素含量中有显著优势, 可为水稻精准变量施肥提供参考。

关键词: 水稻; 氮素含量; 高光谱; 耦合离散小波和一阶微分变换; 人工蜂鸟优化; 极限学习机

中图分类号: S511; TP79 文献标识码: A 文章编号: 1000-1298(2024)12-0306-08

OSID:



Prediction of Nitrogen Content in Rice Leaves Based on DWT - DE Transformation and AHA - ELM Algorithm

LIU Tan^{1,2} WANG Wenqi¹ LI Zimo¹ QI Yuan¹ GUO Zhonghui^{1,2} XU Tongyu^{1,2}

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

2. Liaoning Engineering Research Center for Information Technology in Agriculture, Shenyang 110866, China)

Abstract: In order to provide a rapid, non-destructive, and accurate prediction method for nitrogen content in rice using spectral data, focusing on northeast rice as the research object, hyperspectral data of rice in three growth stages were collected, and combined with indoor chemical experiments, aiming to improve the prediction accuracy and model interpretability of nitrogen content by establishing an inversion model for rice nitrogen content. The acquired hyperspectral data and corresponding nitrogen content of rice leaves were firstly preprocessed by using a low-pass filtering method. For the processed spectral data, a coupling discrete wavelet transform and first-order differential transform (DWT - DE transform) were used for dimensionality reduction, and compared with principal component analysis (PCA) and discrete wavelet multiresolution decomposition methods. The dimensionality-reduced results were used as inputs, and the measured leaf nitrogen content was the output, to establish inversion models by using extreme learning machine (ELM), particle swarm optimization support vector machine (PSO - SVM), and artificial hummingbird algorithm optimized extreme learning machine (AHA - ELM), respectively, for predicting and validating rice leaf nitrogen content. The results showed that the AHA - ELM model established using the results of the coupling discrete wavelet and first-order differential transform had the highest prediction accuracy, which was superior to the ELM and PSO - SVM models. The determination

收稿日期: 2024-01-12 修回日期: 2024-03-06

基金项目: 辽宁省教育厅面上项目(LJKMZ20221035、LJKZ0683)、辽宁省科技厅面上项目(2023-MS-212)、国家自然科学基金项目(32001415)和辽宁省自然科学基金指导计划项目(2019-ZD-0720)

作者简介: 刘潭(1985—),男,副教授,博士,主要从事智能优化算法和农业遥感研究,E-mail: liutan_0822@126.com

通信作者: 许童羽(1967—),男,教授,博士生导师,主要从事农业航空研究,E-mail: xutongyu@syau.edu.cn

coefficient R^2 of the training set was 0.8064, and the root mean square error RMSE was 0.3251 mg/g. The R^2 of the validation set was 0.7915, and the RMSE was 0.3620 mg/g. Therefore, the proposed AHA-ELM model established by DWT-DE transform had significant advantages in the rapid detection of rice nitrogen content, and can provide a good reference for precise variable fertilization in rice.

Key words: rice; nitrogen content; hyperspectral; coupled discrete wavelet transform and first-order differential transform; artificial hummingbird optimization; extreme learning machine

0 引言

水稻是我国主要粮食作物之一。在水稻的生长过程中,氮素作为主要营养物质,在维持和调节水稻生理功能上具有多方面的作用,影响水稻的产量和品质,因此实时监测和评估水稻氮素含量对其长势监测、施肥施药调控及田间的精准管理具有重要意义。近年来,高光谱遥感技术逐渐发展,被广泛应用于农作物营养诊断等方面,为实现作物氮素含量监测提供了一种有效的手段^[1-3]。

采用高光谱成像技术,通过分析光谱数据,可以快速、准确、无损地获取水稻氮素含量、叶绿素含量等农学参数^[4-7],降低了人力和时间成本,提高了反演效率。近年来,在高光谱反演作物氮素含量方面,许多学者开展了广泛研究,并取得了一系列的研究成果。在水稻等作物氮素含量反演研究中,一些学者采用机理模型(如辐射传输模型)研究分析光谱与氮素含量间的定量关系,此类建模方法具有一定物理意义且反演过程较为稳定,但通常模型参数较多且确定复杂。另外,地表环境系统包含许多不确定性因素都会对模型精度产生较大影响。因此,结构简单、分析方便的数据建模方法^[8-12]被广泛应用于氮素反演建模中。此类方法通常将数学变换、微分变换、小波变换、植被指数等用于光谱的处理分析。离散小波变换可有效聚合有益光谱信息,明显增强光谱信息的稳定性。同时,对光谱进行微分等变换操作可强化光谱特征,获取更多有效信息。由于不同的变换方法应用于光谱特征参数提取能有效挖掘出光谱特征^[13],进而提高模型精度,因此,在作物相关指标预测中可结合使用。

综上所述,为进一步提高水稻氮素含量预测精确性和稳定性,本文以东北粳稻为研究对象,采用高光谱成像技术,首先通过低通滤波方法对采集的光谱数据进行预处理,然后对水稻叶片光谱数据降维方法开展研究,基于离散小波变换和一阶微分变换各自优势,采用一种耦合离散小波和一阶微分变换(DWT-DE 变换)方法对光谱数据进行降维,提取光谱特征,接着以提取的光谱特征作为输入,水稻叶片氮素含量为输出,采用人工蜂鸟算法优化极限学习机(AHA-ELM)建立反演模型,并分别与标准极

限学习机(ELM)和粒子群优化支持向量机(PSO-SVM)进行对比,进一步体现所建立模型优势。

1 数据获取与处理

1.1 研究区概况

研究区域位于辽宁省海城市耿庄镇沈阳农业大学精准农业航空科研基地(40°58'45.39" N, 122°43'47.0064" E)。基地位于辽东半岛与东北平原交界处,属于温带季风性气候。年平均气温为 8.4℃,年平均降雨量为 652 mm,日照时数平均为 3663 h。四季分明,土地肥沃,适宜水稻生长。

实验水稻品种为沈农 9816,小区栽培实验设置 4 个氮素水平:0、225、450、675 kg/hm²,每个水平设置 3 个重复,划为 26 个小区。在水稻生长过程中,除了氮肥处理水平不同外,其他均保持一致。

1.2 数据采集

1.2.1 水稻叶片氮素含量测定

在水稻分蘖期、拔节期、抽穗期 3 个生长期分别在实验小区内进行破坏性采样,每个小区取 2~3 穴水稻,低温保存带回实验室。将采集的水稻新鲜叶片剪下,进行杀青和干燥后,称量并研磨粉碎。使用凯氏定氮法对叶片氮素含量进行测量。实验采集到 306 组数据,使用标准差方法对数据进行筛选,剔除异常值,同时采用蒙特卡洛算法将各关键生育期异常光谱数据剔除。对剩余的 293 组样本进行划分,按照比例 7:3 划分为训练集和测试集。划分后训练集 205 组,验证集 88 组,如表 1 所示。

表 1 水稻叶片氮素含量统计

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)	标准差/ (mg·g ⁻¹)
训练集	205	1.01	4.47	2.75	0.73
测试集	88	1.46	4.34	2.65	0.75

1.2.2 叶片高光谱数据采集及处理

本研究使用海洋光学 HR2000+ 型光纤光谱仪,测定光谱范围为 400~1000 nm,分辨率为 0.461 nm。对水稻进行叶片光谱采集时,为保证叶片新鲜,需在 2 h 内完成。在每次测量前,使用标准白板对仪器进行校正,以确保测量结果的准确性。测量过程中,将

仪器探头紧压于水稻叶片上,使用 Ocean View 软件采集高光谱数据。

在采集过程中,由于仪器震动等因素影响,数据存在噪声,容易产生误差,所以需对高光谱数据进行预处理^[14]。使用高斯低通滤波器对高光谱曲线进行滤波处理。高斯低通滤波器以高斯函数作为滤波器窗口函数,具有较好的频率响应和抗混叠性能。设置窗口大小为 5,滤波处理后曲线更平滑,如图 1 所示。




图 1 预处理前后高光谱曲线对比

Fig. 1 Comparison of hyperspectral curves before and after pretreatment

1.3 光谱数据降维

光谱数据中存在大量冗余信息,建模时会影响计算速度,导致误差增大,制约了采用光谱数据对水稻氮素含量预测的能力^[15-16]。因此,采用合理的降维方法对光谱数据进行降维,提取光谱内的有用信息,是建模的前提和基础^[17-18]。本文采用一种耦合离散小波和一阶微分变换法对光谱数据进行降维处理,并分别与主成分分析(PCA)、离散小波多尺度分解方法进行对比。

1.3.1 主成分分析法

主成分分析(PCA)是一种常用的无监督学习方法。它是通过线性变换将原始数据从原始特征空间变换到一个新的低维特征空间,使得数据在新空间中的方差尽可能大^[19]。在新的特征空间中,每个特征被称为主成分。

1.3.2 离散小波多尺度分解

离散小波多尺度分解是一种用于信号分析和处理的数学方法。它是基于小波变换(Wavelet transform)的一种扩展技术,可以将信号分解成不同尺度和频率的成分^[20]。信号在时域上的变换类似于光谱数据在光谱波段上的变换。时域上,信号是通过时间上的变化来描述的,而在光谱波段上,光谱数据是通过频率或波长上的变化进行描述^[21-24]。

1.3.3 耦合离散小波和一阶微分变换

首先对光谱数据进行一阶微分变换,然后将一阶微分光谱进行离散小波变换。对于函数 $f(x)$,其一阶微分变换可表示为

$$f'(x) = \lim_{h \rightarrow \infty} (f(x+h) - f(x)) / h \quad (1)$$

式中 $f'(x)$ ——函数 $f(x)$ 的一阶导数

h ——取极限时的无穷小变化量

当对离散信号一阶微分变换时,可以使用差分运算来近似计算导数。对于离散信号序列 $y(n)$,其一阶微分变换表示为

$$y'(n) = y(n+1) - y(n) \quad (2)$$

式中, $y'(n)$ 为 $y(n)$ 的一阶导数。通过计算相邻样本之间的差异得到一阶微分变换的结果。

当对光谱数据进行一阶微分变换后,得到光谱数据的变化率信息。一阶微分操作可以捕捉到光谱中的局部变化以及峰值、跳跃或陡峭的特征。

然后对一阶微分变换后的数据进行离散小波变换,可以进一步分析光谱信号的频域特征和局部组成。离散小波变换通过将光谱信号分解为不同频率和尺度上的小波系数,可以提供关于信号在不同尺度的频谱信息^[25]。

耦合离散小波和一阶微分(简称离散小波-微分变换)可以综合各自的优点,通过一阶微分变换来突出细微信息,然后使用离散小波变换抑制高频噪声,可以较好地平衡两者之间的特点,提高光谱信息处理的能力,使得分析结果更全面、准确,并具备较好的抑噪能力和特征提取能力^[26-27]。

1.4 反演建模方法

选用极限学习机、粒子群优化的支持向量机和人工蜂鸟优化的极限学习机 3 种方法建立反演模型。根据决定系数 R^2 和均方根误差 RMSE 检验模型精度和准确性。其中, R^2 越接近 1,表明模型预测值与实测值之间的相关性越高; R^2 越接近 0,表明其相关程度越弱。RMSE 越小,表明预测模型精度越高。

1.4.1 极限学习机模型

极限学习机(Extreme learning machine, ELM)是一种机器学习算法,为单层前向神经网络,其独特之处在于随机初始化输出层权重和偏置,而隐藏层权重是固定的随机数。尤其适用于处理大规模数据和需要快速训练的场景^[28]。但 ELM 的随机初始化隐藏层到输出层权重和偏置可能会导致训练结果有不确定性。不同的初始化随机数可能导致不同的模型性能^[29-30]。

1.4.2 人工蜂鸟优化算法模型

本研究采用人工蜂鸟优化算法(Artificial hummingbird algorithm, AHA)对极限学习机进行优化。

每次迭代过程,执行引导觅食和区域觅食的概

率为 50%, 进行 $2n$ 次迭代后, 执行迁移觅食。在 3 种觅食方式中, 均使用 3 种飞行技能。迭代完成后, 将满足条件的全局最优适应度和最优解作为 ELM 的权值和阈值进行预测。

1.4.3 人工蜂鸟算法优化的极限学习机模型

人工蜂鸟算法优化的极限学习机 (AHA-ELM) 模型预测流程如图 2 所示。

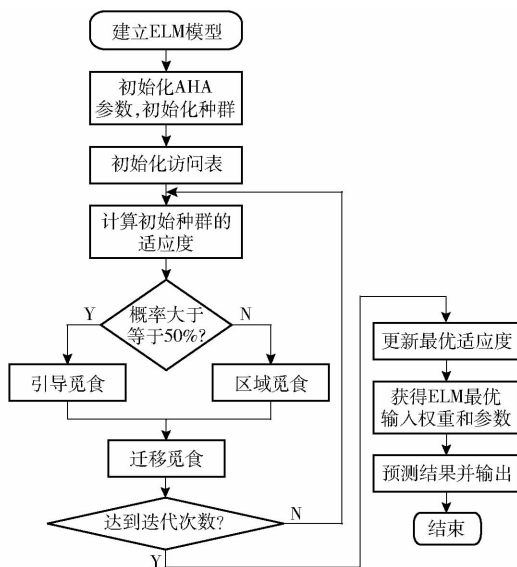


图 2 AHA-ELM 算法流程图

Fig. 2 AHA-ELM algorithm flowchart

具体执行步骤为:

- (1) 构建 ELM 模型, 初始化参数, 包括 AHA 种群大小、最大迭代次数和访问表。
- (2) 将蜂鸟的位置作为 ELM 输入层的权重和阈值, 计算适应度。
- (3) 选择蜂鸟的飞行方式和觅食方式, 并更新适应度和访问表。
- (4) 判断是否满足条件, 如果达到条件, 将更新的最优适应度赋给 ELM。
- (5) ELM 对数据进行预测, 并输出结果。

2 结果与分析

2.1 特征及特征波段选择

2.1.1 主成分分析 (PCA) 提取光谱特征

采用 PCA 方法从全波段反射率数据中提取累计方差贡献率最高的 6 个主成分。各主成分方差贡献率和累计方差贡献率如表 2 所示。由表 2 可知, 前 6 个主成分累计方差贡献率已达 99.80%, 覆盖光谱绝大部分信息。

2.1.2 离散小波多尺度分解提取光谱特征

在使用离散小波多尺度分解进行特征提取时, 需要根据光谱数据的特点和具体应用场景选择合适的小波母函数和尺度, 所以选择最优小波母函数和

最佳分解尺度至关重要。如果分解后的光谱数据能保留目标特征, 即提取到的特征能够对目标问题提供关键有效的信息且不包含冗余信息, 此时小波母函数和分解尺度最佳。

表 2 光谱数据各主成分方差贡献率和累计贡献率

Tab. 2 Variance contribution and cumulative contribution of each principal component of spectral data %

主成分	方差贡献率	累计贡献率
PC1	95.23	95.23
PC2	3.02	98.25
PC3	0.89	99.14
PC4	0.42	99.56
PC5	0.18	99.74
PC6	0.06	99.80

本研究对光谱数据分别采用 db4、sym8 和 coif5 3 种小波母函数进行小波变换, 分解尺度为 2^j ($j=1, 2, \dots, 12$), 标记为尺度 1~12。

对光谱进行 12 级的离散小波多尺度分解后, 可以提取每层分解得到的近似系数。这些近似系数反映了光谱信号在不同尺度上的整体趋势和轮廓特征^[31]。对于每个小波母函数, 在每层分解中, 可以计算出对应的近似系数个数。以此为基础, 可以绘制出分解个数比例随分解层数变化的曲线, 以了解近似系数在不同分解层级上的具体分布情况。这个曲线可以用来分析各个分解层级对光谱信号的重要性以及对信号特征的贡献程度。

另一方面, 利用提取得到的近似系数重构光谱信号。通过对每个小波母函数下的各层近似系数进行重构, 得到重构的光谱信号。然后, 计算与原始光谱信号的相关性。这样可以评估不同小波母函数下每层近似系数对于光谱信号的重构能力和相似度, 如表 3 所示。

分析表 3 可知, coif5 小波母函数具有最多的小波近似系数数目, 压缩数据能力最弱。相比之下, sym8 小波母函数具有较强的压缩数据能力。在分解层数为 10 层以后, 近似系数数目逐渐稳定。由相关系数随分解层数的变化图分析可知, db4 小波母函数在 7~12 层的分解中, 每层相关系数的变化规律和其他 2 类小波母函数不一致, 且相差较大, 故对比 sym8 和 coif5 小波母函数。

可见, 分解层数低于 7, 相关系数变换比较平缓, 在第 7 层分解时, sym8 小波母函数的近似系数数目比 coif5 小波母函数少, 且具有更高的相关系数, 当层数高于 7 后, 随着层数增加, 相关系数减小的幅度明显增加, 近似系数数目减小幅度相对减缓,

表3 不同小波母函数的分解个数

Tab.3 Numbers of decomposition level under different wavelet generating functions

分解 层数	db4			sym8			coif5		
	相关系数	近似系数数目	压缩率/%	相关系数	近似系数数目	压缩率/%	相关系数	近似系数数目	压缩率/%
1	1	676	50.222 9	0.999 8	680	50.520 1	0.999 8	687	51.040 1
2	0.999 6	241	25.334 3	0.999 6	347	25.780 1	0.999 6	358	26.597 3
3	0.999 4	174	12.927 2	0.999 4	181	13.447 3	0.999 3	193	14.338 8
4	0.999 2	90	6.686 5	0.999 2	98	7.280 8	0.999 2	111	8.246 7
5	0.999 1	48	3.566 1	0.999 1	56	4.160 5	0.999 1	70	5.200 6
6	0.998 8	27	2.005 9	0.998 9	35	2.600 3	0.998 9	49	3.640 4
7	0.992 1	17	1.263 0	0.993 9	25	1.857 4	0.993 8	39	2.897 5
8	0.984 3	12	0.891 5	0.973 9	20	1.485 9	0.973 5	34	2.526 0
9	0.939 5	9	0.668 6	0.959 5	17	1.263 0	0.958 0	31	2.303 1
10	0.934 6	8	0.594 4	0.924 1	16	1.188 7	0.926 7	30	2.228 8
11	0.919 4	7	0.520 1	0.921 2	15	1.114 4	0.922 3	29	2.154 5
12	0.871 1	7	0.520 1	0.916 4	15	1.114 4	0.916 3	29	2.154 5

且计算量也会相应增加。因此,综合考虑数据压缩性和保留光谱信息质量的能力,选择 sym8 小波母函数,分解层数为 7 进行分析。在综合考虑确定小波母函数和分解尺度以后,将分解后的小波近似系数作为模型输入建立反演模型。

2.1.3 耦合离散小波和微分变换光谱特征提取

图3为光谱数据经过耦合离散小波和一阶微分变换的波形图,由图3可知,处理后的光谱数据波形平滑,峰谷交替出现,这表明通过一阶微分变换和离散小波变换成功捕捉到了光谱数据中的细节和变化。




图3 光谱经耦合离散小波和一阶微分变换波形

Fig.3 Waveform diagram of spectrum through coupled discrete wavelet and first-order differential transformation

在小波细节系数 d1 ~ d4 内噪声较多,峰谷特征不明显。从 d5 开始,光谱曲线出现较为明显的峰谷特征,但在波段 800 ~ 1 000 nm 中,即“近红外位置”,出现更多的波动,存在更多噪声,所以光谱经耦合离散小波和微分变换后的最佳细节系数为 d6。因此,由图3可知,光谱数据经离散小波变换后,可以得到光谱的多尺度表示,放大细节特征。经过耦合离散小波和微分变换后,在放大细节特征的基础上,降低了解析尺度,并捕捉到光谱更多的细微信息。

2.2 人工蜂鸟算法优化极限学习机反演模型

将光谱反射率数据经过主成分分析(PCA),离散小波多尺度分解,耦合离散小波和一阶微分变换进行特征提取,将获得的结果分别作为输入,氮素含量为输出,采用人工蜂鸟算法优化学习机反演模型对水稻叶片氮素含量进行预测,预测值和实测值的散点图如图4所示。决定系数 R^2 和均方根误差 RMSE 作为模型的评价标准。

由图4可知,采用3种降维方法建立的 AHA-ELM 反演模型预测效果较好,其中,采用耦合离散小波和一阶微分变换方法降维后建立的 AHA-ELM 模型精度最高,训练集 R^2 为 0.806 4,测试集 R^2 为 0.791 5, RMSE 分别为 0.325 1、0.362 0 mg/g。采用主成分分析方法进行降维建模的精度最低,训练集和测试集 R^2 分别为 0.753 3 和 0.750 6, RMSE 分别为 0.362 3、0.393 6 mg/g。而通过离散小波多尺度分解得到的小波近似系数建立的模型精度位于二者之间,训练集和测试集 R^2 分别为 0.767 1 和 0.752 0, RMSE 分别为 0.370 7、0.383 7 mg/g。由对比分析结果可知,在相同预测模型条件下,耦合离散小波和一阶微分变换可较好地降低模型复杂性,进

一步提升模型精度。

2.3 与其他反演模型对比

为了进一步表明人工蜂鸟优化的极限学习机反演模型 (AHA-ELM) 的优越性, 同时采用标准极限

学习机 (ELM) 模型以及目前应用较为广泛的粒子群算法 (Particle swarm optimization, PSO) 优化的支持向量机 (PSO-SVM) 模型对氮素含量预测, 预测结果如图 5、6 所示。




图 4 不同降维方法的 AHA-ELM 模型氮含量预测结果

Fig. 4 Prediction results of nitrogen content by using AHA-ELM model with different dimensionality reduction methods




图 5 不同降维方法的 ELM 模型氮含量预测结果

Fig. 5 Prediction results of nitrogen content by using ELM model with different dimensionality reduction methods

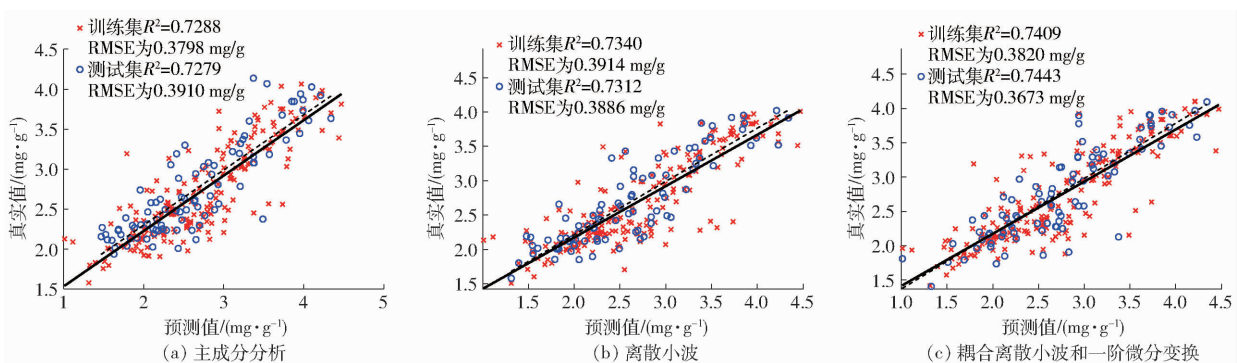


图 6 不同降维方法的 PSO-SVM 模型氮含量预测结果

Fig. 6 Prediction results of nitrogen content by using PSO-SVM model with different dimensionality reduction methods

由图 5、6 可知, 针对同一预测模型, 与其他降维方法相比, 采用 PCA 方法建立的模型精度仍然相对较低。如对于 ELM 模型, 经 PCA 对光谱数据降维后建立的模型沿直线 $y=x$ 呈现较为分散的趋势, 表明预测值与实测值之间存在一定的偏差, 其训练集和验证集 R^2 分别为 0.6868 和 0.6522, RMSE 分别为 0.4063、0.4589 mg/g; 而采用耦合离散小波和一阶微分变换降维后建立 ELM 模型精度相对较高, 训练集和验证集 R^2 分别为 0.7227 和 0.7134, RMSE 分别为 0.3685、0.4239 mg/g。对于 PSO-SVM 模型, 同样采用 PCA 建立的模型精度相对最低, 而采

用耦合离散小波-微分变换建立模型精度更高, 其训练集和验证集 R^2 分别为 0.7409 和 0.7443, RMSE 分别为 0.3820、0.3673 mg/g。进一步体现了耦合离散小波和一阶微分变换能有效提升光谱对水稻氮素含量的预测能力。

通过图 4~6 的仿真结果对比, 从整体建模角度来看, 以相同降维方法为基础进行建模时, 本文构建 AHA-ELM 预测模型的预测结果要优于 ELM 和 PSO-SVM 模型。由此表明, 本文提出的建模方法经人工蜂鸟优化算法对 ELM 进行参数优化后, 可以一定程度提升模型预测精度, 增强模型稳定性。

3 讨论

通过仿真对比发现,在建立的多个模型中,基于DWT-DE变换建立的模型精度高于其他2种降维方法,其次是离散小波多尺度分解后用近似系数建立的反演模型,主要原因可能是离散小波和一阶微分变换都能够突出光谱信号的特征。离散小波变换通过多尺度分解提取不同频率的特征波段,而一阶微分变换通过计算光谱信号的变化率来凸显光谱中的突变点和边缘特征。将这2个方法结合使用,可以更加有效地强化光谱特征,使得数据更易于分析和识别。同时,离散小波变换通过多尺度分解减少噪声的影响,而一阶微分变换可以通过平滑处理来消除噪声的突发性变化。通过这种耦合方式,可以达到更好的噪声抑制和平滑效果,提高数据质量和可靠性。在建立反演模型时,ELM模型对水稻氮素反演精度相对偏低,本文提出的改进AHA-ELM模型精度高于标准ELM模型,且一定程度高于PSO-SVM模型,其原因是标准ELM模型的初始权值和偏置都是随机产生,具有一定的盲目性,而AHA-

ELM模型由于在标准ELM的基础上引入自适应全局搜索策略,优化了ELM权重和偏置,以及提高了模型泛化能力。这些改进使得AHA-ELM模型能够更有效地利用数据和参数,进一步提高模型训练效果和预测准确性。

4 结论

(1)经耦合离散小波和微分变换后,光谱数据在放大细节特征的基础上,降低了分解尺度,并捕捉到光谱更多的细微信息。

(2)在相同预测模型条件下,经耦合离散小波和一阶微分变换对光谱降维作为输入提高了模型的整体性能和预测精度,使模型决定系数 R^2 较大,均方根误差RMSE较小。

(3)在相同的光谱特征输入下,本文提出的AHA-ELM模型能够进一步提高氮含量预测的准确性和稳定性,其中使用DWT-DE变换建立的AHA-ELM模型,训练集和验证集的 R^2 均高于0.7915, RMSE均低于0.3620 mg/g,在预测精度方面优于其他模型。

参 考 文 献

- [1] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12): 277-293.
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12): 277-293. (in Chinese)
- [2] 李粉玲, 常庆瑞. 基于连续统去除法的冬小麦叶片全氮含量估算[J]. 农业机械学报, 2017, 48(7): 174-179.
LI Fenling, CHANG Qingrui. Estimation of winter wheat leaf nitrogen content based on continuum removed spectra[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(7): 174-179. (in Chinese)
- [3] 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)
- [4] 祝海竣. 基于机器学习的水稻叶片SPAD值和氮素含量的高光谱估测研究[D]. 长沙: 湖南农业大学, 2021.
ZHU Haijun. Research on hyperspectral estimation of rice leaf SPAD and nitrogen content based on machine learning[D]. Changsha: Hunan Agricultural University, 2021. (in Chinese)
- [5] 刘伟, 王建平, 刘长虹, 等. 基于粒子群寻优的支持向量机番茄红素含量预测[J]. 农业机械学报, 2012, 43(4): 143-147.
LIU Wei, WANG Jianping, LIU Changhong, et al. Lycopene content prediction based on support vector machine with particle swarm optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(4): 143-147. (in Chinese)
- [6] ZHANG Jiayi, QIU Xiaolei, WU Yueting, et al. Combining texture, color, and vegetation indices from fixed-wing UAS imagery to estimate wheat growth parameters using multivariate regression methods[J]. Computers and Electronics in Agriculture, 2021, 185: 106138.
- [7] LU J, DAI E, MIAO Y, et al. Improving active canopy sensor-based in-season rice nitrogen status diagnosis and recommendation using multi-source data fusion with machine learning[J]. Journal of Cleaner Production, 2022, 380: 134926.
- [8] 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)
- [9] 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 nutrition based on UAV hyperspectral images[J]. Transactions of the CSAE, 2020, 36(22): 31-39. (in Chinese)
- [10] 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)
- [11] 陈春玲, 金彦, 曹英丽, 等. 基于GA-BP神经网络高光谱反演模型分析玉米叶片叶绿素含量[J]. 沈阳农业大学学报, 2018, 18(5): 626-632.

- CHEN Chunling, JIN Yan, CAO Yingli, et al. Analysis of chlorophyll contents in maize leaf based on GA-BP neural network hyperspectral inversion mode[J]. *Journal of Shenyang Agricultural University*, 2018, 18(5): 626-632. (in Chinese)
- [12] 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 Xuqing, LIU Xiangnan, LIU Meiling, et al. Random forest algorithm and regional applications of spectral inversion model for estimating canopy nitrogen concentration in rice[J]. *Journal of Remote Sensing*, 2014, 18(4): 923-945. (in Chinese)
- [13] 周贝贝, 李恒凯, 龙北平. 离子吸附型稀土矿区复垦植被光谱特征变异提取与分析[J]. *光谱学与光谱分析*, 2023, 43(12): 3946-3954.
- ZHOU Beibei, LI Hengkai, LONG Beiping. Variation analysis of spectral characteristics of reclaimed vegetation in an ionic rare earth mining area[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(12): 3946-3954. (in Chinese)
- [14] ZHANG J, WANG C, YUAN L, et al. Construction of a plant spectral library based on an optimised feature selection method [J]. *Biosystems Engineering*, 2020, 195: 1-16.
- [15] HSIEH T H, KIANG J F. Comparison of CNN algorithms on hyperspectral image classification in agricultural lands [J]. *Sensors*, 2020, 20 (6): 1734-1751.
- [16] 邢思敏. 基于特征转移指数和仿生优化算法的粳稻冠层氮含量反演研究[D]. 沈阳: 沈阳农业大学, 2022.
- XING Simin. Inversion of nitrogen content of japonica rice canopy based on feature transfer index and bionic optimization algorithm[D]. Shenyang: Shenyang Agricultural University, 2022. (in Chinese)
- [17] 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.
- [18] 张新乐, 于溢洋, 李厚莹, 等. 东北水稻叶片 SPAD 遥感光谱估算模型[J]. *中国农业大学学报*, 2020, 25(1): 66-75.
- ZHANG Xinle, YU Ziyang, LI Houxuan, et al. Remote sensing estimation model of SPAD for rice leaves in Northeast China [J]. *Journal of China Agricultural University*, 2020, 25(1): 66-75. (in Chinese)
- [19] 刘爽, 于海业, 张郡赫, 等. 基于最优光谱指数的大豆叶片叶绿素含量反演模型研究[J]. *光谱学与光谱分析*, 2021, 41(6): 1912-1919.
- LIU Shuang, YU Haiye, ZHANG Junhe, et al. Study on inversion model of chlorophyll content in soybean leaf based on optimal spectral indices[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(6): 1912-1919. (in Chinese)
- [20] 王丹, 赵朋, 孙家波, 等. 基于无人机多光谱的夏玉米叶绿素含量反演研究[J]. *山东农业科学*, 2021, 53(6): 121-126, 132.
- WANG Dan, ZHAO Peng, SUN Jiabo, et al. Inversion of chlorophyll content in summer maize based on UAV multi-spectrum [J]. *Journal of Shandong Agricultural Sciences*, 2021, 53(6): 121-126, 132. (in Chinese)
- [21] 傅友强, 钟旭华, 黄农荣, 等. 基于无人机多光谱遥感的水稻冠层光谱特征和氮素营养关系研究[J]. *广东农业科学*, 2021, 48(10): 121-131.
- FU Youqiang, ZHONG Xuhua, HUANG Nongrong, et al. Research on relationship between canopy spectral characteristics and nitrogen nutrient of rice cultivars based on UAV multispectral remote sensing [J]. *Guangdong Agricultural Sciences*, 2021, 48(10): 121-131. (in Chinese)
- [22] LI W Y, WU W X, YU M L, et al. Monitoring rice grain protein accumulation dynamics based on UAV multispectral data [J]. *Field Crops Research*, 2023, 294: 108858.
- [23] 王延仓, 李笑芳, 李莉婕, 等. 基于离散小波-微分变换算法定量反演火龙果茎枝叶绿素含量的研究[J]. *光谱学与光谱分析*, 2023, 43(2): 549-556.
- WANG Yancang, LI Xiaofang, LI Lijie, et al. Quantitative inversion of chlorophyll content in stem and branch of pitaya based on discrete wavelet differential transform algorithm [J]. *Spectroscopy and Spectral Analysis*, 2023, 43(2): 549-556. (in Chinese)
- [24] PAN Y, WU W, ZHANG J, et al. Estimating leaf nitrogen and chlorophyll content in wheat by correcting canopy structure effect through multi-angular remote sensing [J]. *Computers and Electronics in Agriculture*, 2023, 208: 107769.
- [25] PAN Y, ZHOU R, ZHANG J, et al. A new spectral index for estimation of wheat canopy chlorophyll density: considering background interference and view zenith angle effect [J]. *Precision Agriculture*, 2023, 24(5): 2098-2125.
- [26] LI D, CHEN J M, ZHU Y, et al. Estimating leaf nitrogen content by coupling a nitrogen allocation model with canopy reflectance [J]. *Remote Sensing of Environment*, 2022, 283: 113314.
- [27] FU Z, YU S, ZHANG J, et al. Combining UAV multispectral imagery and ecological factors to estimate leaf nitrogen and grain protein content of wheat [J]. *European Journal of Agronomy*, 2022, 132: 126405.
- [28] LI H, ZHANG J, XU K, et al. Spectral monitoring of wheat leaf nitrogen content based on canopy structure information compensation [J]. *Computers and Electronics in Agriculture*, 2021, 190: 106434.
- [29] XU K, ZHANG J, LI H, et al. Spectrum-and RGB-D-based image fusion for the prediction of nitrogen accumulation in wheat [J]. *Remote Sensing*, 2020, 12(24): 4040.
- [30] 王凡, 陈龙跃, 段丹丹, 等. 小波分析的茶鲜叶全氮含量高光谱监测[J]. *光谱学与光谱分析*, 2022, 42(10): 3235-3242.
- WANG Fan, CHEN Longyue, DUAN Dandan, et al. Estimation of total nitrogen content in fresh tea leaves based on wavelet analysis [J]. *Spectroscopy and Spectral Analysis*, 2022, 42(10): 3235-3242. (in Chinese)
- [31] 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)