

DOI: 10.13718/j.cnki.xdzk.2026.02.007

张坤, 刘霞, 李语琳, 等. 基于混合海鸥算法优化 PLSR 的果园土壤有效氮含量预测方法 [J]. 西南大学学报(自然科学版), 2026, 48(2): 76-84.

基于混合海鸥算法优化 PLSR 的 果园土壤有效氮含量预测方法

张坤¹, 刘霞¹, 李语琳¹, 田洋²,
吕强¹, 王克健³, 谢让金¹, 易时来¹

1. 西南大学 柑桔研究所/国家柑桔工程技术研究中心, 重庆 400712;
2. 重庆三峡职业学院 农林科技学院, 重庆 404155; 3. 全国农业技术推广服务中心, 北京 100125

摘要: 氮素是作物营养三要素之一, 也是施肥管理重点监测的营养元素之一, 如何快速无损监测土壤有效氮含量, 对作物精准高效土壤施氮具有重要作用。分别采用一阶导数(First Derivative, D1)、二阶导数(Second Derivative, D2)、标准正态变量变换(Standard Normal Variable, SNV)、平滑滤波函数(Smoothing Gaussian, SG)、小波变换(Wavelet Transform, WAVE)5 种光谱预处理方法来去除光谱噪声, 比较不同光谱预处理的建模效果; 通过竞争自适应重加权采样法(Competitive Adaptive Reweighted Sampling, CARS)来选取与土壤有效氮含量关联度较高的特征波段; 采用支持向量机回归(Support Vector Regression, SVR)、偏最小二乘回归(Partial Least Squares Regression, PLSR)、海鸥算法(Seagull Optimization Algorithm, SOA)等建立与优化得到土壤有效氮含量预测模型。结果表明: 5 种光谱预处理方法中, 一阶导数(D1)光谱预处理后的效果相对最好, 且 SOA 算法建模效果最佳, 其次是 PLSR, SVR 相对最差; 综合试验结果得出, D1 光谱预处理建立的 S-PLSR 模型(D1-CARS-S-PLSR)预测性能最佳, 其 R^2 为 0.96, RMSE 为 7.07, 比 PLSR 模型的 R^2 提高了 9.6%, RMSE 降低了 33.3%。可见, 基于混合海鸥算法优化 PLSR 建立的果园土壤有效氮含量预测方法为果园智能施肥技术之土壤有效氮水平快速诊断提供了可能。

关键词: 土壤有效氮含量; 高光谱成像技术; 海鸥算法;
偏最小二乘回归

中图分类号: S158.2; TP181

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1673-9868(2026)02-0076-09



A Prediction Method of Available Nitrogen Content in Orchard Soil Based on PLSR Optimized by Hybrid Seagull Optimization Algorithm

ZHANG Kun¹, LIU Xia¹, LI Yulin¹, TIAN Yang²,
LYU Qiang¹, WANG Kejian³, XIE Rangjin¹, YI Shilai¹

收稿日期: 2025-09-26

基金项目: 重庆市技术创新与应用发展专项(CSTB2025TIAD-qykjggX0057); 重庆市万州区科技局项目(wzstc-20220129)。

作者简介: 张坤, 硕士研究生, 主要从事柑橘栽培与农业信息技术研究。

通信作者: 易时来, 副研究员。

1. Citrus Research Institute, Southwest University/National Citrus Engineering Research Center, Chongqing 400712, China;
2. College of Agriculture and Forestry Science and Technology, Chongqing Three Gorges Vocational College, Chongqing 404155, China;
3. National Agro-Tech Extension and Service Center, Beijing 100125, China

Abstract: Nitrogen is one of the three essential elements for crop nutrition and also one of the key nutrient elements under focused monitoring in fertilization management. How to achieve rapid non-destructive monitoring of soil available nitrogen content plays a crucial role in accurate and efficient soil nitrogen application for crops. In this paper, five spectral preprocessing methods were used to remove noise from the spectrum, namely first derivative (D1), second derivative (D2), standard normal variable (SNV), smoothing gaussian (SG), and wavelet transform (WAVE). The modeling effects of different spectral preprocessing methods were compared; meanwhile, the competitive adaptive reweighted sampling (CARS) method was adopted to select characteristic bands with high correlation with soil available nitrogen content. Subsequently, prediction models for soil available nitrogen content were established and optimized using support vector regression (SVR), partial least squares regression (PLSR), and seagull optimization algorithm (SOA), respectively. The results showed that among the five spectral preprocessing methods, the first derivative (D1) preprocessing achieved the best effect. In terms of modeling performance, the SOA algorithm was the most effective, followed by PLSR, while SVR was relatively the worst. Among all models, the S-PLSR model obtained after D1 spectral preprocessing (D1-CARS-S-PLSR model) exhibited the optimal prediction performance, with a coefficient of determination (R^2) of 0.96 and a root mean square error (RMSE) of 7.07. Compared with the original PLSR model, the R^2 of the D1-CARS-S-PLSR model was increased by 9.6%, and the RMSE was decreased by 33.3%. It can be concluded that the prediction method for orchard soil available nitrogen content based on PLSR optimized by the hybrid seagull optimization algorithm provides a possibility for the accurate diagnosis of soil available nitrogen levels in the context of orchard intelligent fertilization technology.

Key words: soil available nitrogen content; hyperspectral imaging technology; seagull algorithm; partial least squares regression

柑橘是我国种植面积和产量最大的水果作物,对我国南方农村乡村振兴发挥了重要作用^[1]。氮是柑橘生长发育的三大必需营养元素之一^[2],但过量施氮可能会造成柑橘植株徒长^[3]、花芽分化受阻^[4]、果实酸度增加^[5]、果皮增厚与转色推迟等问题,不仅增加肥料成本,而且还破坏土壤环境。因此,快速监测诊断果园土壤有效氮含量进而科学合理施氮,对柑橘优质丰产栽培具有十分重要的意义。

近年来,高光谱成像技术作为一种快速无损检测植株与土壤中物质含量的技术广受关注,且取得了一定进展。彭杰等^[6]利用便携式地物光谱仪建立了4种不同类型土壤全氮含量高光谱反演预测模型;刘霞等^[7]利用蝙蝠算法建立了柑橘叶片氮含量PLSR预测模型;赵建贵等^[8]建立了番茄叶片光合色素含量高光谱预测模型(CARS-IRIV-PLSR)。基于此,本研究在传统模型的基础上,通过一阶导数、二阶导数、平滑滤波函数、标准正态变量变换和小波变换等5种光谱预处理方法,建立其与土壤有效氮含量之间的相关性,采用支持向量机回归、偏最小二乘回归以及海鸥算法的智能优化偏最小二乘回归来构建不同预测模型,通过比较各模型的预测精度,筛选最适宜的光谱预处理方法、特征波段选择和建模算法,以期建立一种快速无损果园土壤有效氮含量预测技术提供理论依据与方法。

1 材料与方法

1.1 研究区概况

本试验于 2023—2024 年度在重庆市北碚区歇马街道西南大学柑桔研究所栽培与智慧化中心试验示范园中进行。果园位于北纬 29°45′、东经 106°22′, 气候为亚热带季风气候, 年均日照时长为 1 224 h, 年均降水量为 1 351 mm, 年均气温为 19 °C。果园土壤为紫色土, 其中土壤有机质含量为 30.69 g/kg, pH 值为 7.46, 碱解氮含量为 98.38 mg/kg, 有效磷含量为 110.39 mg/kg, 速效钾含量为 275.37 mg/kg, 有效镁含量为 23.75 mg/kg, 有效钙含量为 783.81 mg/kg。试验材料为果园采集的 150 个土壤样品。

1.2 数据测量

土壤样品于 2024 年 12 月随机采自西南大学柑桔研究所栽培与智慧化中心试验示范园, 每个土壤样品采集同一株果树四周沿滴水线 0~45 cm 深处的 4 个均匀土块, 通过四分法进行混合取样, 大约 1 kg/样。样品带回实验室风干, 研磨后用 20 目筛网全部过筛, 150 个样品随机分成训练集 96 个, 测试集 30 个, 验证集 24 个, 使用便携式地物光谱仪(ASD)进行图像数据采集, 采用碱解氮扩散法^[9]测定土壤有效氮含量, 结果如表 1 示。

表 1 土壤有效氮含量分析

样本集	样本数/个	含氮量范围/(mg · kg ⁻¹)	含氮量均值/(mg · kg ⁻¹)	标准误差
训练集	96	24~183	97	4.2
测试集	30	51~174	99	6.6
验证集	24	56~137	85	5.5

1.3 数据分析

高光谱数据通过美国 ASD 公司研制生产的 FieldSpec4 Standard-Res 便携式地物光谱仪进行采集, 所获得的光谱数据使用 Python 3.11 对其进行各种光谱预处理、提取特征光谱和建立模型。利用 R 语言进行相关性分析。

2 高光谱数据采集与处理

2.1 数据采集与校正

采用便携式地物光谱仪采集高光谱数据, 该仪器主要用于野外地表反射率、辐射率等光谱数据测量, 核心结构分为硬件系统和软件系统两部分^[10]。其中, 硬件系统包括光学探头、光谱仪主机、控制与储存单元、校准和辅助配件等; 软件系统主要为采集软件(ViewSpec Pro)。在地物光谱测量前, 需进行黑白校正以消除仪器噪声和环境干扰, 校正公式如下:

$$R(\lambda) = \frac{V_{\text{target}}(\lambda) - V_{\text{dark}}(\lambda)}{V_{\text{white}}(\lambda) - V_{\text{dark}}(\lambda)} \quad (1)$$

式中: $V_{\text{target}}(\lambda)$ 为目标物的原始光谱信号(未校正的 DN 值); $V_{\text{dark}}(\lambda)$ 为暗电流信号(盖上镜头盖或使用黑筒测量的背景噪声); $V_{\text{white}}(\lambda)$ 为白板参考信号(标准反射板的 DN 值)。

2.2 特征波段筛选

本研究采用竞争自适应重加权采样法(Competitive Adaptive Reweighted Sampling, CARS)进行特征波段的选取。通过模拟“达尔文进化论”的竞争机制^[11], 自适应地筛选出对建模最重要的变量, 从而提高建模的预测精度和可解释性^[12-13]。

2.3 模型构建

2.3.1 支持向量机回归模型

支持向量机回归模型(Support Vector Regression, SVR)^[14]利用已经输入的空间和超平面内找到一条

拟合函数并构建一条宽度为 2α 的间隔带,如图 1 所示,SVR 并不要求目标穿过所有点,容忍小误差,若训练值位于条带内,则预测正确。图 1 中, $\pm\alpha$ 表示支持向量机的随机误差, $f(x) = \alpha^R x + \beta$ 表示超平面。本模型采用 SVR 来预测土壤有效氮含量,以光谱特征为 x 变量,并将这些特征投射至高维超平面,然后进行泛化拟合^[15-17]。

2.3.2 偏最小二乘回归模型

偏最小二乘回归(Partial Least Squares Regression, PLSR)^[18]是一种多元统计分析方法,主要应用于处理预测变量多重共线问题或预测变量数量多于观测样本数量时进行回归建模。PLSR 会将高维的预测变量和响应变量投影到新的低维空间,在这个新的低维空间中建立回归关系,然后再投影回高维原始空间,并建立新的综合变量,新变量可以较好解释自变量与因变量之间的协方差^[19-20]。

2.3.3 结合海鸥算法智能优化

海鸥优化算法(Seagull Optimization Algorithm, SOA)^[21]是一种模拟自然界海鸥迁徙和攻击(捕食)行为的群体智能优化算法。它的核心流程包括迁徙(避免碰撞、向最佳邻居方向移动、靠近最佳位置)和攻击猎物。在优化偏最小二乘回归(PLSR)模型时,海鸥算法主要用于确定 PLSR 模型的最佳成分数量,从而提高模型的预测性能。

1) 初始化海鸥种群。随机生成一组“海鸥”,每只海鸥代表一个可能的 PLSR 成分数量。成分数量的取值范围通常由用户指定。例如,在代码中,海鸥的初始位置(即成分数量)是通过随机数生成的,范围为 $n_components_range = [2, 20]$ 。

2) 适应度评估。对每只海鸥的适应度进行评估。适应度函数通常定义为模型的负均方根误差(RMSE)。在 PLSR 模型中,适应度函数为:

$$\text{Fitness} = -\sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (2)$$

式中: y_i 为真实值; \hat{y}_i 为预测值; m 为验证集的样本数量。适应度值越小,表示模型性能越好。

3) 位置更新。根据适应度值更新每只海鸥的位置(即成分数量)。位置更新规则结合了全局搜索和局部搜索。全局搜索:海鸥会随机调整位置,探索新的成分数量。局部搜索:海鸥会向当前最优解(即适应度最高的海鸥)靠近,进行局部优化。

4) 迭代优化。重复上述适应度评估和位置更新过程,直到达到预设的最大迭代次数。在每次迭代中,算法会记录当前最优的成分数量,并将其作为全局最优解。

5) 输出最优解。最终输出最优的 PLSR 成分数量,用于训练最终的 PLSR 模型。

6) PLSR 模型训练与评估。使用海鸥算法优化后的成分数量训练 PLSR 模型,并在训练集、验证集和测试集上评估模型性能。

2.4 模型评价

模型评价指标采用预测值和实测值的决定系数(R^2)和均方根误差(RMSE)来进行判断, R^2 越接近 1, RMSE 越小,则说明模型精准度越高。计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i^\wedge - y_i)^2}{\sum_{i=1}^m (\bar{y} - y_i)^2} \quad (3)$$




图 1 支持向量机模型

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (4)$$

其中: y_i 表示土壤有效氮含量的实测值; \hat{y}_i 表示土壤有效氮含量的预测值; \bar{y}_i 表示实测值的平均值; m 表示预测值的数量。

3 结果与分析

3.1 光谱变换及相关性分析

由图 2 可知, 原始光谱(OS)在全波段的反射率与氮含量之间均表现为极显著的负相关, 并在波长为 2 269 nm 至 2 283 nm 相关性最高, $R^2 = -0.59$; D1 处理后, 在波长 2 201 nm 处 ($R^2 = 0.63$) 和 2 257 nm 处 ($R^2 = -0.72$) 与氮含量的相关性达到最高正相关和负相关; 经过 D2 处理后, 在波长 1 379 nm 和波长 1 416 nm 处与氮含量的相关性最强, R^2 分别为 0.40 和 -0.57 ; 经过 SNV 变换后在波长 1 432 nm 和 1 433 nm 处正相关性最强, $R^2 = 0.77$, 在波长 2 160 nm 和 2 161 nm 处负相关性最强, $R^2 = -0.53$; 经过 SG 变换后与 OS 曲线基本一致, 同样在 2 269 nm 至 2 283 nm 相关性最高, $R^2 = -0.59$; 经过 WAVE 处理后, 波长在 2 271 nm 至 2 278 nm 处与氮相关性最强, $R^2 = -0.59$ 。综合上述, D1 预处理效果相较于其他处理更为理想, 相关系数无论是正相关还是负相关均高于其他预处理方式。




图 2 土壤原始反射光谱及其不同光谱预处理变换后与有效氮含量的相关性分析

3.2 特征波段筛选


图 3 为基于竞争自适应重加权采样法(CARS)选取的原始光谱和经过各种预处理后的特征波段, 以 SG 为例, 随着蒙特卡洛迭代次数的不断增加, 选取的特征波段数量和 RMSECV 在不断下降, 当运行到 24 次时, RMSECV 达到最小, 随后逐渐增加。故在 24 次时确定特征波段, 此时选择的特征波段数为 81。同理, 从 D1、D2、SNV、WAVE 4 个处理的变换后的光谱中分别选取 124、165、94、124 次。可见, 经过 CARS 选取的特征波段比较均匀。

3.3 PLSR 和 SVR 模型估测土壤有效氮含量结果


使用不同光谱预处理变换、特征波段选取算法预测土壤有效氮含量的精确度尚不清楚, 因此, 需建立不同的模型预测土壤有效氮含量, 结果如图 4 所示。对于原始光谱(OS), PLSR 的模型精度要高于 SVR; 经过 D1、D2、SG、SNV、WAVE 5 种预处理后, PLSR 模型预测土壤有效氮含量的精确度均不同程度地优于 SVR 模型, 表现为 PLSR 模型的 R^2 要高于 SVR 模型, PLSR 的 RMSE 要低于 SVR 模型。

3.4 基于混合海鸥智能算法优化 PLSR 模型预测土壤有效氮含量


为了建立相对更准确的回归预测模型, 本研究在 PLSR 模型基础上采用海鸥算法(SOA)进行改良优化, 以提高模型的预测精度, 得到了 R^2 更高和 RMSE 更低的 S-PLSR 模型。如图 5 所示, 相比 PLSR 模型, S-PLSR 模型的 R^2 提高了 5.4%, RMSE 降低了 14.5%, 可见, 基于 SOA 优化的 PLSR 模型可以更加精准的预测土壤有效氮含量。同时, D1 预处理的 R^2 达到了 0.96, RMSE 仅为 7.07, 为 5 个光谱预处理中预测精度最高的一种方式(图 6)。



a. 蒙特卡洛迭代次数与选取样本数之间的关系

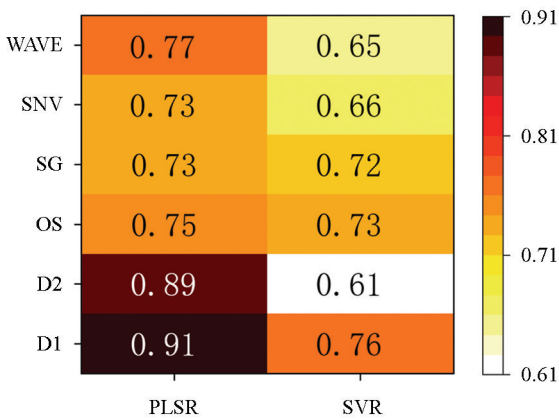


b. 蒙特卡洛迭代次数与RMSECV之间的关系

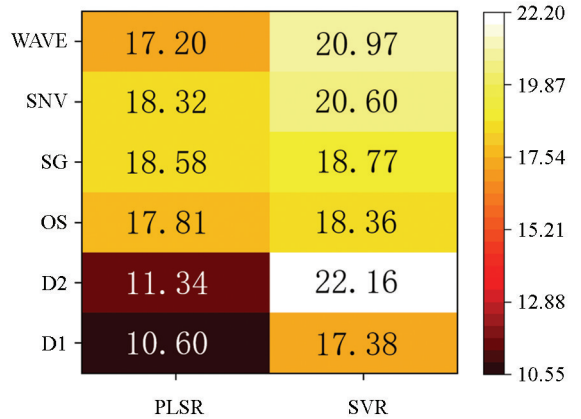


c. 特征波段选取结果

图 3 CARS 算法选取特征波段



a. PLSR和S-PLSR模型验证集的决定系数(R^2)



b. PLSR和S-PLSR模型验证集的均方根误差(RMSE)

图 4 SVR 和 PLSR 模型验证集的决定系数(R^2)与均方根误差(RMSE)

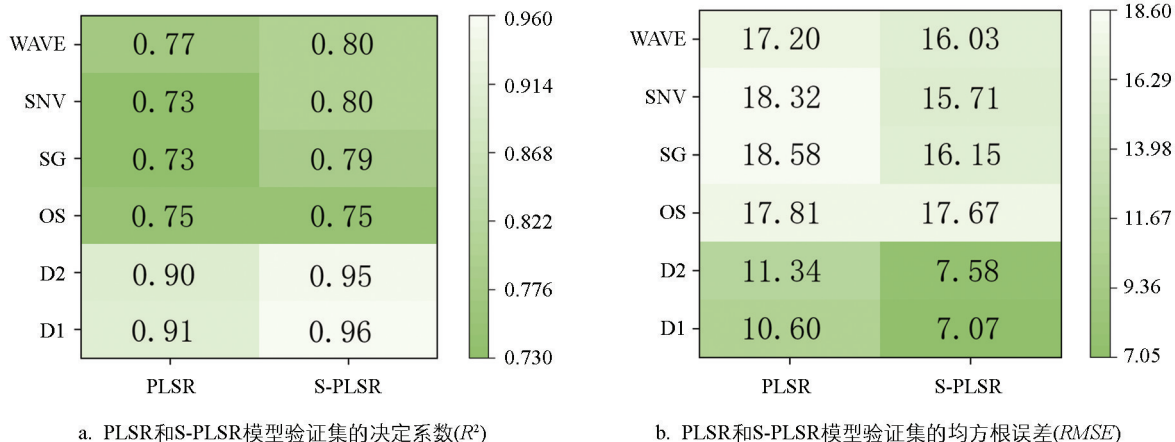


图 5 PLSR 和 S-PLSR 模型验证集的决定系数 (R^2) 与均方根误差 ($RMSE$)

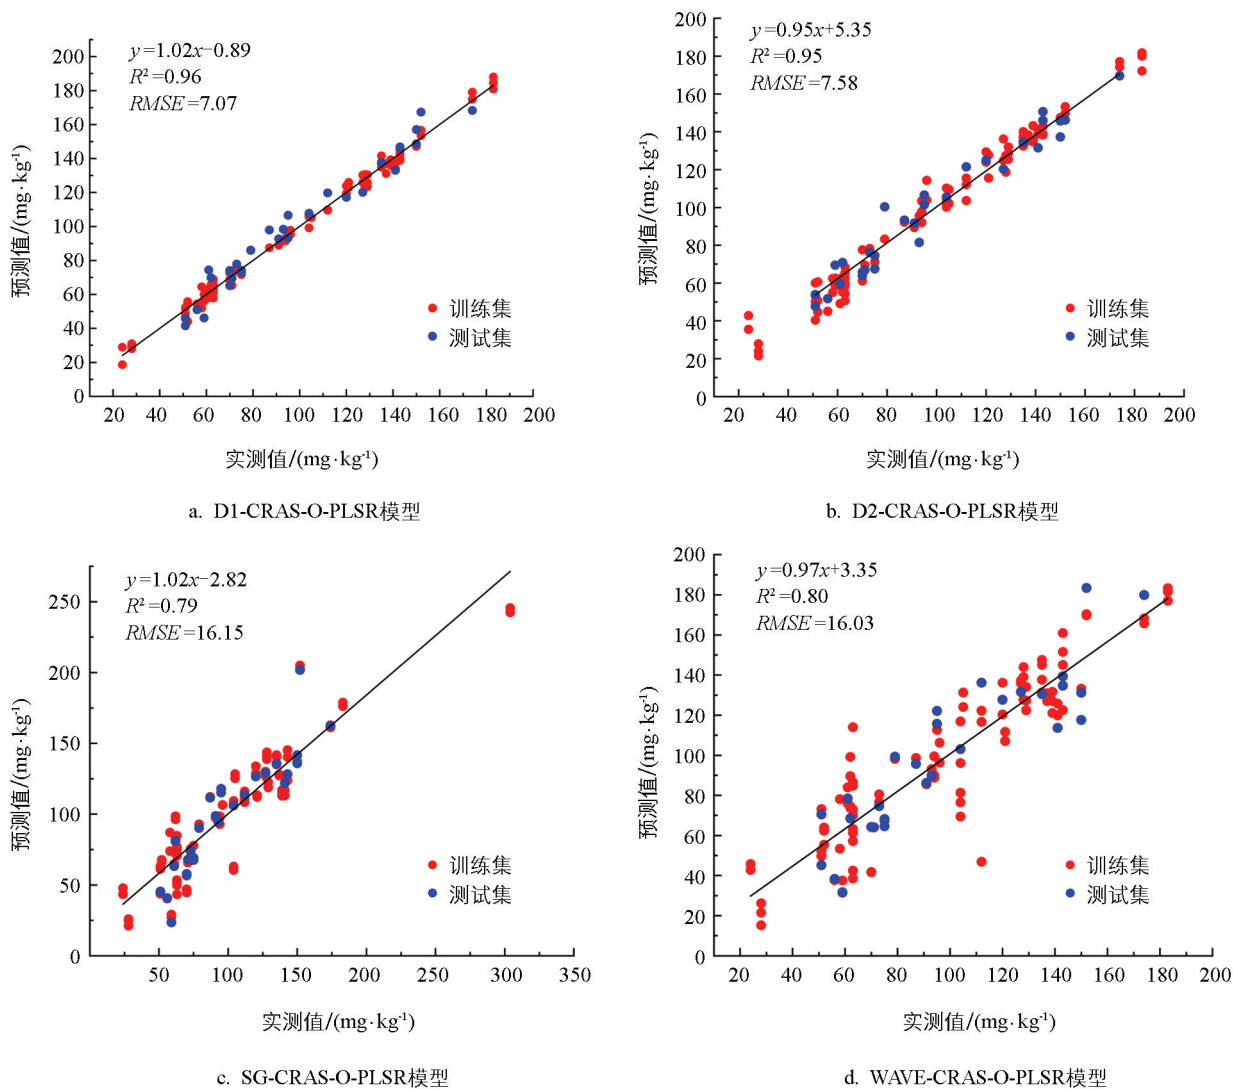


图 6 不同模型验证集的决定系数 (R^2) 与均方根误差 ($RMSE$)

4 讨论与结论

4.1 讨论

本研究采用 5 种光谱预处理方法对原始光谱进行处理, 以降低光谱数据噪声, 来提高建模预测土

壤有效氮含量的精度。使用 CARS 进行特征波段筛选, 再对原始光谱和 5 种预处理后选取的光谱分别进行建模, 得到 PLSR 模型和 SVR 模型; 使用海鸥算法对 PLSR 模型进行进一步智能优化得到了最终的 S-PLSR 模型, 其中 D1 光谱预处理建模的土壤有效氮含量预测精度相对最高。与陈红艳等^[22]、徐永明等^[23]的研究结果一致, 这可能是由于一阶导数精准匹配了光谱噪声消除与有效信息增强的结果, 即同时兼顾“降噪效果”和“特征保留”。从特征波段选取角度看, CARS 算法在不同预处理光谱中筛选出的特征波段数量存在明显差异, 其中 D1 预处理后筛选了 124 个特征波段, 其波长分布与土壤有效氮含量的敏感光谱区间(2 200~2 300 nm)的 N-H 键伸缩振动波段重合度最高, 从而提高了相应建模预测精度。

本研究采用 PLSR、SVR、S-PLSR 3 种算法进行建模, 结果表明, 不同光谱预处理下, PLSR 的 R^2 均高于 SVR, RMSE 均低于 SVR, 这与裴志福等^[24]的研究结果相似, PLSR 算法所建立柑橘土壤有效氮含量预测模型比 SVR 具有相对更高的精度。可能与 PLSR 是一种融合主成分分析、典型相关分析和多元线性回归优势的多元统计数据分析方法, 主要用于解决多因变量对多自变量的回归建模问题, 专门针对适应高维复杂信息的数据结构和问题设计的算法^[25]。它通过有监督的潜变量提取, 高效地解决了维数灾难和多重共线性问题, 直接从海量光谱数据中提炼出对预测目标最相关的信息, 同时以较低的模型复杂度和易于控制的过拟合风险, 在小样本条件下实现了优异的泛化性能^[26]。SVR 是一种强大且灵活的通用算法, 在处理复杂非线性关系或样本量相对充足的非光谱问题上可能表现更好^[27]。然而, 在光谱分析的特定约束条件下, 其灵活性反而可能成为负担(如难以选择最优核和参数、过拟合风险高), 导致其在实际应用中平均精度往往低于精心构建的 PLSR 模型。当然, 具体哪个模型更好最终取决于具体的数据集和问题, 但 PLSR 在光谱领域被广泛采用并取得优异成果, 正是源于其算法特性与数据特性的高度契合。在经过 SOA 算法智能优化后, 得到了 S-PLSR 模型, 相较于 PLSR 模型, S-PLSR 的 R^2 得到了不同程度的提高, RMSE 也显著降低, 这说明在 PLSR 模型的基础上, SOA 优化后的 S-PLSR 模型预测精准度更高。从优化参数的角度来看, 这可能是由于海鸥算法突破了传统参数选择方法的局部最优局限, PLSR 的预测性能高度依赖潜在变量数(LVs), 传统交叉验证或经验法常因搜索范围有限, 导致 LVs 过少或过多。而 SOA 通过模拟海鸥“迁徙-攻击”的群体智能行为, 在预设的 LVs 范围(2~20 个)内实现全局搜索, 其以模型测试集 RMSE 的负值为适应度函数, 通过迭代更新筛选出预测误差相对最小的 LVs, 因此, 其优化后的模型精度相对更高。

目前, 大量数据模型分析系统被应用于高光谱数据与元素含量预测的关系之中, PLSR 作为应用较为广泛的模型之一, 其优化途径仍需不断拓展。本研究采用海鸥算法对 PLSR 模型进行优化建立了 D1-CARS-S-PLSR 模型, 得到了较好的柑橘土壤有效氮含量预测结果, 验证集决定系数 R^2 高达 0.96, 可见, S-PLSR 模型可以为柑橘土壤有效氮含量的估测提供一种新的技术路径, 研究结果可为柑橘生产精准施氮的土壤有效氮含量快速无损监测提供有效方法。虽然本研究初步建立了基于高光谱技术的柑橘土壤有效氮含量预测技术, 但采集的土壤样品仍需进行土壤水分与土壤颗粒大小等的简单前处理才能得到较为理想的光谱信息, 今后可通过田间大量实时样本的训练学习与建模优化, 有望实现真正意义上的田间在线实时检测。

4.2 结论

本研究采用 D1、D2、SG、SNV、WAVE 5 种方式对原始光谱进行预处理, 利用 CARS 进行特征波段的筛选, 结合 SVR 和 PLSR 算法建模, 最后通过 SOA 对 PLSR 进行智能优化, 初步建立了柑橘土壤有效氮含量预测精度相对较高的 S-PLSR 模型, 其中 D1 光谱预处理的模型精度相对最高, 建立的 D1-CARS-S-PLSR 模型表现出最佳的预测性能, 其 R^2 为 0.96, RMSE 为 7.07。

参考文献:

- [1] 文刚, 杨阳, 易春燕, 等. 四川省柑橘木虱发生为害现状与综合防控技术对策 [J]. 四川农业科技, 2024(11): 67-70.
- [2] 周小杰, 赵禹, 王梓, 等. 氮肥和钾肥对晚熟柑橘春见幼树生长的影响 [J]. 四川农业科技, 2022(3): 52-55.

- [3] 顾鑫,任翠梅,杨丽,等. 不同施氮水平对旱地菊芋生长及产量的影响 [J]. 北方园艺, 2017(22): 108-112.
- [4] 郭润泽. 秸秆配施氮肥对设施土壤性状及黄瓜生长和品质的影响 [D]. 保定: 河北农业大学, 2022.
- [5] 章蓉月. 重庆万州金秋砂糖橘的生长特征及施肥处理的研究 [D]. 万州: 重庆三峡学院, 2024.
- [6] 彭杰,向红英,周清,等. 不同类型土壤全氮含量的高光谱预测研究 [J]. 中国农学通报, 2013, 29(9): 105-111.
- [7] 刘霞,周凌霄,夏心杰,等. 基于混合蝙蝠智能算法优化 PLSR 的柑橘叶片氮含量预测方法 [J]. 西南大学学报(自然科学版), 2025, 47(2): 160-170.
- [8] 赵建贵,王国梁,张宇,等. 番茄苗期叶位色素含量高光谱检测及可视化研究 [J]. 光谱学与光谱分析, 2024, 44(2): 386-391.
- [9] 王虹. 土壤肥料分析方法 [M]. 沈阳: 辽宁大学出版社, 1991.
- [10] 余政军,尹小红,杨柳,等. ASD FieldSpec 3 Hi-Res 地物光谱仪的使用与维护 [J]. 中国仪器仪表, 2024(4): 80-84.
- [11] 冷月. 香精香料品质分析方法的研究与应用 [D]. 贵阳: 贵州医科大学, 2024.
- [12] 徐佛言,赵欣,张晓瑞,等. 基于高光谱成像的咸鸭蛋腌制品快速检测 [J]. 食品工业科技, 2024, 45(2): 260-268.
- [13] 李振. 基于无人机高光谱的农田土壤盐分估测研究 [D]. 济南: 山东师范大学, 2023.
- [14] 刘莹. 非参数模型在经济学研究中的应用综述 [J]. 统计与决策, 2025, 41(14): 35-40.
- [15] PRIYADHARSHINI C A, ARULKUMARAN G. Multi-Constraints Feature Selection-Based Cross-Pattern Heterogeneous Ensemble Learning Model for Diabetic Mellitus Prediction under Data-Imbalance and Insufficiency [J]. SN Computer Science, 2025, 6(7): 831.
- [16] CARTA A, FRIGAU L. Tree Oblique for Regression with Weighted Support Vector Machine [J]. Computational Statistics, 2025, 40(9): 5257-5291.
- [17] FANG R Q, YUE M L, WU K Y, et al. Radiomics Nomogram from Multiparametric Magnetic Resonance Imaging for Preoperative Prediction of Substantial Lymphovascular Space Invasion in Endometrial Cancer [J]. Abdominal Radiology, 2025: 1-12.
- [18] ZHANG Z T, QIN H, WU X Y, et al. The Response of Chlorophyll *a* to Nutrient and Hydro-Meteorological Factors in Lake Taihu [J]. Environmental Monitoring and Assessment, 2025, 197(3): 345.
- [19] 王凯东. 基于肯德尔相关系数的矩阵偏最小二乘方法 [D]. 南昌: 江西财经大学, 2024.
- [20] 李智缘,田安红. 基于光谱指数的土壤重金属 Zn 的定量预测与空间分布研究 [J]. 光谱学与光谱分析, 2024, 44(11): 3287-3293.
- [21] 覃木宝,王华,王龙林,等. 基于改进海鸥算法优化支持向量机的斜拉桥索力优化研究 [J]. 森林工程, 2023, 39(4): 160-169.
- [22] 陈红艳,赵庚星,张晓辉,等. 基于遗传算法结合偏最小二乘的潮土碱解氮高光谱特征及含量估测 [J]. 中国农学通报, 2015, 31(2): 209-214.
- [23] 徐永明,蔺启忠,黄秀华,等. 利用可见光/近红外反射光谱估算土壤总氮含量的实验研究 [J]. 地理与地理信息科学, 2005, 21(1): 19-22.
- [24] 裴志福,沈钦国,范若渝,等. 基于中红外光谱的内蒙古区域农田土壤有机碳预测模型研究 [J]. 土壤通报, 2024, 55(5): 1264-1272.
- [25] 李硕. 基于可见近红外成像光谱技术土壤剖面氮的预测研究 [D]. 武汉: 华中农业大学, 2013.
- [26] JIANG H, WANG Z Y, DENG J H, et al. Quantitative Detection of Heavy Metal Cd in Vegetable Oils: A Nondestructive Method Based on Raman Spectroscopy Combined with Chemometrics [J]. Journal of Food Science, 2024, 89(11): 8054-8065.
- [27] JUBAYER M F, NILOY S, SARKER M A R, et al. Leveraging Machine Learning to Predict Potato Shelf Life: A Comprehensive Analysis in an Evaporative Cooling Structure [J]. Potato Research, 2025, 68(4): 4257-4281.