doi:10.6041/j.issn.1000-1298.2026.17.013

基于无人机遥感特征选择的冬小麦氮营养指数估测模型研究

苏宝峰[1,2]　张云皓[1,2]　龚　正[1,2]　罗炜松[1,2]　聂灵芝[1,2]　孙浩天[1,2]

（1.西北农林科技大学机械与电子工程学院，杨凌 712100；2.农业农村部农业物联网重点实验室，杨凌 712100）

摘要：氮营养指数（Nitrogen nutrition index，NNI）是表征冬小麦氮营养状态及辅助精准施肥决策的关键指标。尽管无人机遥感技术为大面积快速获取 NNI 提供了有效手段，但如何科学融合多维遥感特征、优化特征筛选流程并构建高精度估测模型，仍是当前提升 NNI 监测精度的难点。本研究基于无人机遥感数据，提取并组合植被指数特征和冠层结构特征，提出了一种基于 Shapley additive explanations（SHAP）算法与递归消除的特征选择方法，该方法量化了每个特征对模型预测的贡献，能更精确地筛选出关键特征。使用 PLSR（Partial least squares regression）、KNN（K-nearest neighbors）、GPR（Gaussian process regression）、XGBoost（Extreme gradient boosting）、AutoGluon 共 5 种算法构建冬小麦氮营养指数估测模型，并进行有效评估。结果表明：特征融合与筛选显著提升了估测精度，从融合特征中筛选出的 23 个核心特征在模型表现上最优，精度由大到小为融合特征、植被指数特征、冠层结构特征的规律，证明了多维特征互补及筛选优化在提升 NNI 监测性能中的关键作用；在模型精度对比中，AutoGluon 在 3 种特征组合下均表现最佳，最高 R^2 达到 0.78，显示出良好的稳定性与泛化能力。本研究识别了氮营养反演的有效特征，提升了拔节期冬小麦 NNI 的估测精度，为精准施肥提供了科学依据。

关键词：冬小麦；氮营养指数；估测模型；多源数据融合；自动机器学习模型；夏普利加性解释

中图分类号：S24；S31　　**文献标识码**：A　　**文章编号**：1000-1298（2026）17-0134-10　　**OSID**：

Estimation of Nitrogen Nutrition Index in Winter Wheat Based on UAV Remote Sensing and Feature Selection

Su Baofeng[1,2]　Zhang Yunhao[1,2]　Gong Zheng[1,2]　Luo Weisong[1,2]　Nie Lingzhi[1,2]　Sun Haotian[1,2]

（1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Internet of Things*, *Ministry of Agriculture and Rural Affairs*, *Yangling*, *Shaanxi* 712100, *China*）

Abstract: The nitrogen nutrition index (NNI) served as a critical indicator for characterizing the nitrogen status of winter wheat and supporting precision fertilization decision-making. Although UAV-based remote sensing technology provided an effective means for the rapid, large-scale acquisition of NNI, scientifically integrating multidimensional remote sensing features, optimizing feature selection workflows, and constructing high-precision estimation models remained significant challenges in improving NNI monitoring accuracy. Multi-source remote sensing data was utilized to extract and combine vegetation index features and canopy structural features, and a feature selection method was proposed based on Shapley additive explanations (SHAP) and recursive feature elimination (RFE). By integrating SHAP values with the recursive elimination strategy, it was able to more accurately identify key features. Five algorithms, i.e., partial least squares regression (PLSR), K-nearest neighbors (KNN), Gaussian process regression (GPR), extreme gradient boosting (XGBoost) and AutoGluon were employed to construct nitrogen nutrition index estimation models for winter wheat, with comprehensive model evaluation conducted. The results showed that the integration and selection of features significantly enhanced the estimation accuracy. Among the configurations tested, the 23 core features selected from the fused feature set achieved the optimal model performance. The accuracy followed the hierarchical

收稿日期：2026-01-30　修回日期：2026-02-04

基金项目：宁夏回族自治区重点研发计划项目（2023BCF01001）

作者简介：苏宝峰（1981—），男，教授，博士，主要从事田间植物表型获取及应用研究，E-mail：bfs@nwsuaf.edu.cn

order of fused features, vegetation indices, and canopy structural features, which demonstrated that the complementarity of multidimensional features and the optimization of feature selection played a crucial role in improving NNI monitoring performance. In the comparison of model accuracies, AutoGluon performed the best across all three feature combinations, reaching a maximum R^2 of 0.78, which exhibited robust stability and generalization capability. The research result identified effective features for nitrogen inversion and improved the estimation accuracy of NNI during the jointing stage of winter wheat, providing a scientific basis for precision fertilization and field management.

Key words: winter wheat; nitrogen nutrition index; estimation model; multi-source data fusion; automatic machine learning model; Shapley additive explanation

0　引言

氮素是影响小麦产量的关键营养物质,其精确估计对生产管理至关重要[1]。氮肥过量或施用不当会导致产量波动、成本增加,并引发温室气体排放及水土污染等环境问题[2]。因此,研发实时、精准的作物氮素评估技术,对于优化施肥方案、提升利用效率及稳定小麦产量具有重要意义。近年来,氮营养指数(Nitrogen nutrition index, NNI)作为植物实际氮浓度(Plant nitrogen content, PNC)与临界氮浓度(Critical nitrogen concentration, Nc)的比值,被认为是诊断作物氮状况的有效指标[3]。相比传统人工破坏性采样并化学分析所面临的耗时长、成本高等问题[4],利用搭载高通量光谱传感器的无人机平台,可在不影响作物生长的前提下,实现对冬小麦 NNI 的快速无损评估[5]。

为解决单一遥感特征感知力不足的问题,多源特征融合已成为提升作物参数监测精度的重要手段[6]。研究表明,结合多光谱、可见光与热成像特征可显著增强 NNI 诊断模型的性能[7]。此外,整合光谱反射率与纹理特征并结合机器学习算法,能有效提升氮含量预测效果[8]。然而,无人机遥感数据在时空分辨率及作物敏感性上的差异仍增加了建模难度,如何高效利用这些多维图像特征进行表型分析,依然是当前面临的重要挑战[9]。

传统线性回归难以处理复杂的非线性关系,限制了表型分析的准确性与普适性。随着遥感与数据挖掘技术的发展,机器学习在精准农业中广泛应用,如融合 RGB 与多光谱影像并利用 RF、GPR 或 XGBoost 等算法,可显著提升小麦氮含量的估算精度,最优模型 R^2 达到 0.84[10]。然而,传统机器学习高度依赖专家经验,存在参数调整可重复性差的问题。自动机器学习(Automatic machine learning, AutoML)通过自动化特征工程与超参数优化,提供了更高效的建模方案[11]。即便如此,无人机影像提取的海量特征仍导致模型复杂、算力消耗大,如何筛选冗余变量以简化模型、提高运算效率已成为当前的研究重点[12]。目前特征变量筛选的方法主要包括过滤法、包装法和嵌入法等[13-14]。然而这些方法只通过单一特征与目标变量之间的关系来筛选特征,忽略了特征之间的交互作用和冗余问题,同时也不能有效解释特征与模型输出的关系,从而限制了模型的可解释性。

本研究基于无人机遥感数据融合,提出一种面向冬小麦拔节期 NNI 估测的特征选择方法。该方法结合夏普利加性解释(Shapley additive explanations, SHAP)与递归消除思想,利用 SHAP 算法量化特征对估测结果的边际贡献,以取代传统的特征重要性排序,从而更精确地揭示关键特征[15]。在此基础上,采用 AutoML 构建评估模型,旨在提升拔节期追肥阶段 NNI 的反演精度,为冬小麦的精准施肥与田间管理提供科学依据。

1　材料与方法

1.1　实验设计

实验地点为江苏省苏州市昆山陆家农事综合服务中心无人农场(31°17′47.84″N,121°02′28.44″E),该地区位于长江中下游,平均海拔约为 3.4 m,年平均气温约 18.3℃,年平均降水量 1 670.5 mm 左右,年平均日照时数约 1 853.4 h,土壤属于乌栅土,取样测定 pH 值为 7.64,有机质质量分数为 15.57 g/kg,全氮质量分数为 1.86 g/kg,有效磷质量分数为 26.98 mg/kg,有利的气候及土壤条件为种植冬小麦提供了良好的基础。

本研究在 2024—2025 年进行了为期 1 年的梯度施肥实验,实验冬小麦品种为镇麦 20,共设置了 4 个氮浓度梯度:N1(0 kg/hm^2)、N2(120 kg/hm^2)、N3(240 kg/hm^2)、N4(360 kg/hm^2)。基肥、分蘖肥、拔节肥、穗肥的施用比例为 5∶1∶2∶2,每个氮浓度设 4 次重复,使用随机区组设计设置了 16 个实验区域,小区面积 80 m^2(10 m×8 m),每个实验区域均匀设置 9 个采样点。地面样本数据采集的时间点主要在需要追施肥料的拔节期。研究区域和采样时间如图 1 所示。

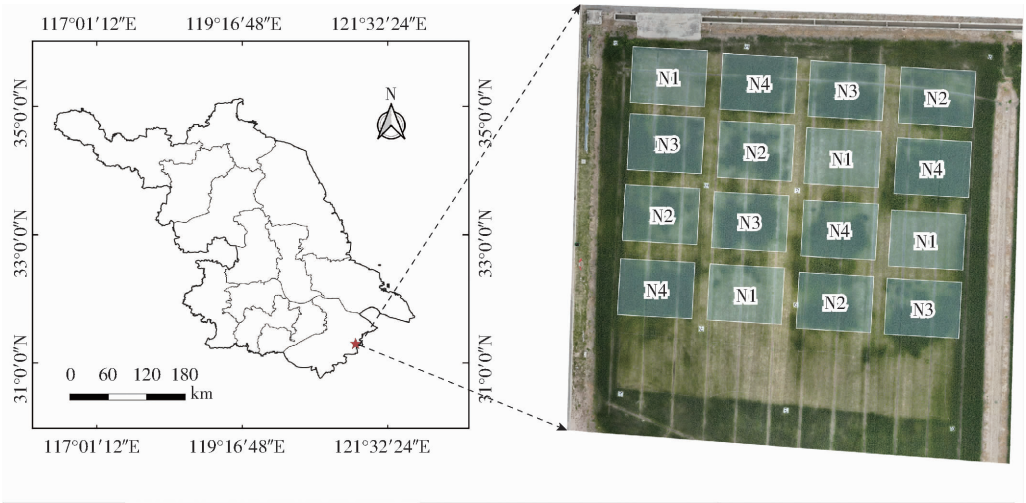

农事作业	2024年12月						2025年1月						2025年2月					
	5	10	15	20	25	30	5	10	15	20	25	30	5	10	15	20	25	30
施肥		✓							✓									
样本采集									✓					✓			✓	
遥感数据采集	✓				✓			✓			✓		✓			✓		

农事作业	2025年3月						2025年4月						2025年5月					
	5	10	15	20	25	30	5	10	15	20	25	30	5	10	15	20	25	30
施肥	✓						✓											
样本采集	✓		✓			✓			✓		✓							
遥感数据采集	✓		✓			✓		✓			✓				✓			✓

图 1 研究区域和实验设计

Fig. 1 Study area and experimental design

1.2 数据获取及处理

1.2.1 无人机遥感数据获取及处理

实验期间,在小麦追肥的拔节期使用 Mavic 3 Multispectral RTK 无人机进行了 3 次影像采集。该无人机配备了 5 个 CMOS 传感器,包括 1 个 RGB 传感器和 1 个包含绿(Green, G)、红(Red, R)、红边(Rededge, RE)、近红外(Near-infrared, NIR)波段的传感器,有效像素均为 500 万。为确保数据质量,采样均在 10:00—14:00 晴朗天气下进行,飞行高度 30 m,速度 3 m/s,且航向与旁向重叠率分别为 90% 和 85%。利用 Pix4D 软件对影像进行拼接、正射校正和辐射标定,生成了分辨率为 1.41 cm/像素的多光谱、RGB 影像、点云及 DSM 数据。处理过程中,使用设置在实验田中的 10 个地面控制点(Ground control points, GCPs)对图像进行偏移校准、使用辐射校准板进行辐射校准,确保数据的准确性与可用性。

1.2.2 地面数据获取与处理

田间调查包括手动测量鲜质量、干质量和 PNC。采样时在预先设置的采样点进行破坏性采样,每个采样点采集 5 株样本。冬小麦植株连同根部一起取出,用水洗净,用剪刀剪掉根部,将洗净的样品分成叶和茎,放入 105℃的烘箱中杀青 30 min,然后在约 80℃下烘干至恒质量并称量作为干质量,同时计算地上植物干质量。叶和茎的 PNC 采用凯氏定氮法进行测定。

1.2.3 氮营养指数及追肥量计算

NNI 被用于评估作物在整个生育期内的氮素营养状况。NNI 定义为植物实际氮浓度(Actual nitrogen concentration, N_a)与 N_c 的比值(其中,N_c 是在特定地上植物干物质量(Plant dry mass, W_{PDM})下,维持最优生长所需的最低氮浓度)[16],反映了植物氮素供应是否满足最优生长需求。若 NNI 等于 1,表明作物氮素营养水平处于最佳状态,高于 1 为氮营养过剩,低于 1 则氮营养不足。N_c 与地上部干物质量的关系呈负幂函数形式[17],表达式为

$$N_c = 4.16 \times W_{PDM}^{-0.41} \times 100\% \tag{1}$$

参数 4.16 和 −0.41 参考了王晓玲[18]的研究结果,该研究基于长江中下游区域连续 3 年的田间实验,涵盖了 6 个冬小麦品种,建立的模型在区域代表性与稳定性方面均表现良好,适用于本研究区的作物营养诊断。为进一步量化追肥需求,本研究构建了基于 NNI 的施肥量计算公式

$$R_N = \frac{W_{PDM} N_c (1 - R_{NNI})}{R_{NUE}} \tag{2}$$

式中 R_N——最终追肥的纯氮量,kg/hm^2

W_{PDM}和 N_c 的乘积代表作物达到最大生长潜力时所需的理想氮积累量;$1 - R_{NNI}$则量化了植株相对于理想营养状态的氮素亏缺比例;R_{NUE}表示氮利用率,取

固定值 0.426[18]。

1.3　特征提取

1.3.1　植被指数特征提取

无人机采集的多光谱影像包含 R、G、RE 和 NIR 共 4 个波段。基于这些波段，本研究共计算了 26 种植被指数（Vegetation index，VI），具体指数为：CIG[19]、CIRE[19]、CVI[20]、DVI[21]、GDVI[21]、GNDVI[13]、GOSAVI[22]、GRDVI[21]、GRVI[21]、GSAVI[23]、MEVI[21]、MGRVI[24]、MNDI[21]、MNLI[21]、MSR[25]、MTCI[26]、NDRE[13]、NDVI[21]、OSAVI[13]、PNDVI[21]、RDVI[21]、RENDVI[27]、REOSAVI[22]、RVI[21]、SAVI[21]、WDRVI[22]。这些指数主要通过波段反射率之间的差值、比值、归一化差值及指数变换等方法计算得出，旨在增强多光谱波段对作物氮素差异的响应能力。所有植被指数的计算均在 Python 平台上完成。

1.3.2　冠层结构特征提取

冠层结构特征（Canopy structure，CS）主要包括纹理特征与点云特征两大类。纹理特征提取自每个多光谱波段，每个波段在固定的滑动窗口（5 像素 × 5 像素）和步长（2 像素）设置下，共提取 8 个纹理指标，总计得到 32 个特征。点云特征则从基于无人机获取的高分辨率三维点云数据（.las 格式）和 DSM 数据中提取，每个波段提取了 9 个反映冠层垂直结构的几何特征，共计 45 个特征。两类特征的全称及其缩写见表 1。

表 1　冠层结构特征

Tab.1　Canopy structure feature

特征类别	特征名与缩写
纹理特征	平均值（mean value，mn）、方差（variance，var）、同质性（homogeneity，hom）、二阶矩（second moment，sm）、对比度（contrast，con）、差异度（dissimilarity，diss）、熵（entropy，ent）、相关性（correlation，corr）
点云特征	最大高度（max height，maxH）、平均高度（mean height，meanH）、标准差（standard deviation，stdD）、四分位距（interquartile range，iqr）、25% 百分位数（25% percentile，p25）、75% 百分位数（75% percentile，p75）、偏度（skewness，skew）、峰度（kurtosis，kurt）、点密度（point density，pd）、极差（range，rng）、中位数（median，med）

1.4　特征选择

本研究提出了一种基于 SHAP 与递归消除的特征选择方法。该方法以随机森林为基学习器（超参数 max_depth 等于 12，random_state 等于 42）[12]，通过计算样本的 SHAP 值矩阵，量化每个特征对模型预测的边际贡献。随后，借鉴递归消除思想，依据特征的平均绝对 SHAP 值进行排序，并逐步增加高贡献度的特征。在每一次特征子集迭代中，均重新训练模型并评估其性能，最终通过比较不同特征子集下的性能指标，确定最优特征组合，算法流程图如图 2 所示。此策略不仅能有效识别并保留高贡献特征，还能缓解多重共线性与特征冗余问题，从而在提升模型预测性能的同时，确保其泛化能力与可解释性。

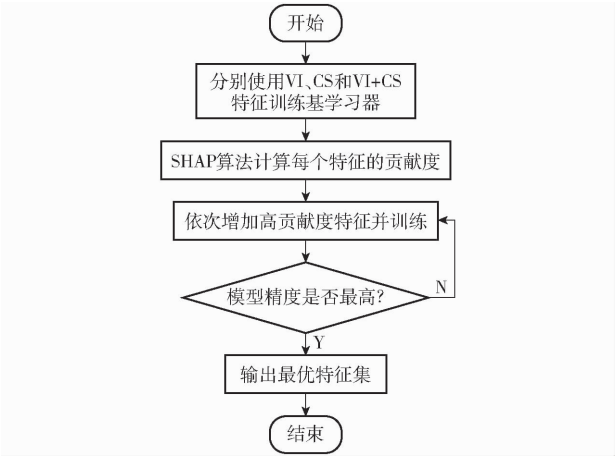

图 2　基于 SHAP 值与递归消除的混合特征选择算法流程图

Fig.2　Flowchart of mixed feature selection algorithm based on SHAP value and recursive elimination

1.5　模型构建与评估

采用了 4 种广泛使用的机器学习方法进行 NNI 回归建模，分别是：偏最小二乘回归（Partial least squares regression，PLSR）[28]、K 最近邻算法（K-nearest neighbors，KNN）[29]、高斯过程回归（Gaussian process regression，GPR）[30]、XGBoost[31]。此外还使用了一种 AutoML 模型：AutoGluon[32]。所有机器学习模型均通过 Python 中的 Scikit-learn 库构建，主要超参数通过粒子群算法（Particle swarm optimization，PSO）进行优化[33]。训练过程中，数据集按比例 8∶2 划分为训练集和测试集[12]。模型训练完成后，采用多种性能评价指标对训练结果进行系统评估，包括均方根误差（Root mean square error，RMSE）、平均绝对误差（Mean absolute error，MAE）、预测残差偏差比（Residual prediction deviation，RPD）、决定系数（Coefficient of determination，R^2）。

2　结果与分析

2.1　氮营养指数与特征变量相关性分析

为探究对 NNI 敏感的特征，首先对 26 种植被

指数与 77 种结构进行了 Pearson 相关分析，对相关系数大于 0.2 的特征进行可视化（图 3）。结果表明，不同类型特征对 NNI 的响应程度存在明显差异。植被指数与 NNI 之间表现出较强的正相关性，多个指数相关系数超过 0.6，反映出其对氮素供应水平变化具有较好的指示能力。尤其在包含 NIR 波段的植被指数（如 GOSAVI、GRDVI、GSAVI）中，相关性最为显著，说明氮素营养状况对 NIR 波段响应强烈。相比之下，冠层结构特征与 NNI 的相关性普遍处于中低水平，除 NIR_mn 的相关系数超过 0.6 外，其余结构特征相关系数介于 0.2 ~ 0.4 之间，表明其解释能力相对有限。

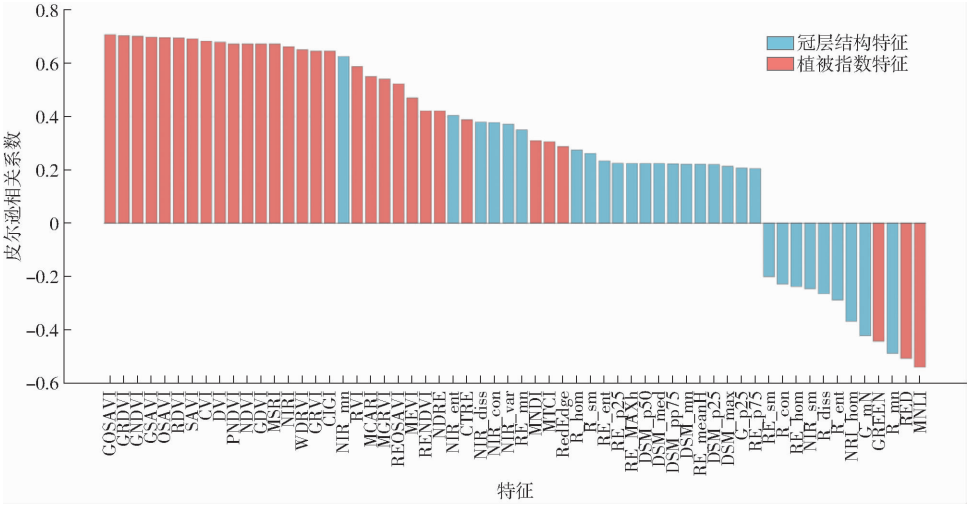

图 3 氮营养指数与全部特征变量的相关性分析

Fig. 3 Correlation analysis between nitrogen nutrition index and all characteristic variables

2.2 植株氮营养指数敏感特征变量筛选

随后，采用基于 SHAP 值与递归消除的混合特征选择方法，分别对植被指数特征、冠层结构特征以及二者融合后的特征集进行筛选，结果如表 2 与图 4 所示。在冠层结构特征筛选中，共筛选出 13 个特征，基学习器模型 R^2 达到 0.65。其中，NIR_mn 特征的 SHAP 贡献度显著高于其他特征，与 Pearson 相关性分析结果一致，进一步确认了该特征在反映氮素状况中的核心作用。植被指数特征筛选得到 11 个特征，模型 R^2 为 0.70。重要性排名靠前的 SAVI、RDVI、CVI 等指数均包含 NIR 波段，再次印证了近红外信息对氮营养指数的敏感性与解释力，说明光谱指数对氮素变化具有直接而稳定的响应能力。

表 2 单特征及融合特征筛选结果

Tab. 2 Screening results of single feature and fusion feature

特征类别	特征总数	筛选特征数	筛选结果
冠层结构特征（CS）	77	13	NIR_mn, RE_pd, R_mn, G_p75, RE_maxH, R_iqrH, G_kurt, RE_p25, CHM_rng, RE_mn, NIR_corr, R_var, NIR_var
植被指数特征（VI）	26	11	SAVI, RDVI, CVI, GRDVI, GOSAVI, NIR, OSAVI, GSAVI, MCARI, DVI, MTCI
融合特征（CS + VI）	108	23	SAVI, RDVI, GOSAVI, RE_pd, OSAVI, CVI, GRDVI, NIR, GSAVI, RE_kurt, RE_mn, R_iqrH, RE_maxH, CHM_std, G_diss, G_sm, CHM_rng, RE_iqrH, CHM_CV, RE_p25, G_kurt, MGRVI, DVI

在融合特征筛选中，特征重要性整体呈现“植被指数优先”的格局，SAVI、RDVI、GSAVI 等仍居于前列，而部分冠层结构特征如 RE_mn、R_sd 的贡献度也显著提升，反映出两类特征间存在一定的互补性。融合特征模型的性能最优，在选取 23 个特征时达到最佳（R^2 = 0.73），表明在光谱信息基础上引入结构特征，可有效增强模型对不同植被覆盖与冠层空间变化的适应能力，提升泛化性能。此外，随着递归过程中特征数量的增加，3 类特征集的模型精度均在达到峰值后趋于稳定或出现下降，说明部分特征存在冗余，也从侧面验证了特征筛选方法的有效性与必要性。

2.3 特征融合建模对比

将筛选出的特征，分别使用 PLSR、KNN、GPR、XGBoost、AutoGluon 机器学习回归算法建立 NNI 估测模型，训练结果见表 3 和图 5，图中 ** 表示极显著相关（$P < 0.01$）。从模型性能对比来看，PLSR、KNN、GPR、XGBoost 与 AutoGluon 模型的 R^2 范围分

别为 0.52 ~ 0.73、0.58 ~ 0.68、0.50 ~ 0.66、0.70 ~ 0.74 和 0.74 ~ 0.78。其中，传统机器学习模型（PLSR、KNN、GPR）的精度普遍较低，集成模型（XGBoost）的精度略高于传统机器学习模型，AutoGluon 模型的预测精度显著优于传统机器学习与集成模型。尤其在使用融合特征建模时，AutoGluon 的 RPD 评价指标达到 2.15，表明该模型不仅能准确反映氮营养指数变化，亦具备良好的稳定性与泛化能力，为作物氮营养监测提供了可靠的技术支持。

从特征组合角度分析，PLSR、KNN、GPR、XGBoost 与 AutoGluon 模型在冠层结构特征建模中的 R^2 分别为 0.52、0.58、0.50、0.70、0.74，在植被指数特征建模中的 R^2 分别为 0.65、0.65、0.66、0.73、0.75，在融合特征中的 R^2 分别为 0.73、0.68、0.62、0.74、0.78。所有模型的精度均呈现植被指数特征优于冠层结构特征，进一步验证了植被指数对氮营养状态具有更高的敏感性。在融合特征与单一特征对比中，除 GPR 模型外，其余模型的精度排序均为 CS + VI > VI > CS，说明融合特征能有效整合两类信息的优势，进一步提升模型估计性能。

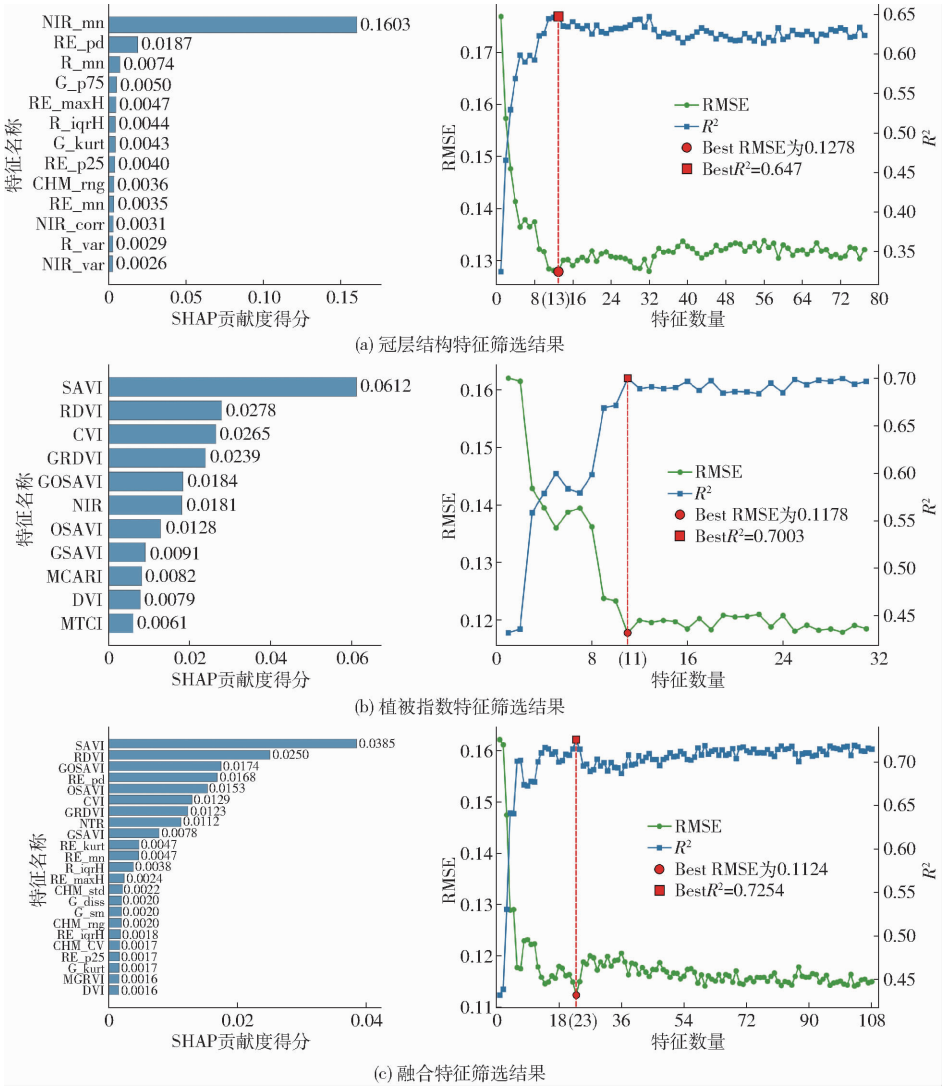

图 4　基于 SHAP 的特征筛选结果及特征贡献度分析

Fig. 4　Feature selection results and feature contribution analysis based on SHAP algorithm

2.4　消融实验

为了验证所提出的特征选择方法的有效性，使用 2.3 节被证实最优的 AutoGluon 算法，进行不同特征筛选方法之间的对比（SHAP、Pearson、无筛选方法），其中 Pearson 筛选的特征为 2.1 节（图 3）中所有相关性大于 0.2 的特征。实验结果如表 4 和图 6 所示。使用 Pearson 筛选方法在冠层结构特征、植被指数特征及融合特征上的建模 R^2 分别是 0.65、0.69、0.72，不使用任何筛选方法的建模 R^2 分别是 0.62、0.58、0.66，均低于使用 SHAP 方法筛选后的 R^2 结果（0.74、0.75、0.78）。这表明，本研究采用基于 SHAP 的递归特征筛选方法，通过剔除冗余变量并捕捉非线性贡献，提升了模型估测精度。

表 3 冬小麦 NNI 估算模型精度对比

Tab. 3 Accuracy comparison of winter wheat NNI estimation model

模型	特征变量	模型评估指标			
		R^2	RMSE	MAE	RPD
PLSR	冠层结构特征(CS)	0.52	0.14	0.11	1.44
	植被指数特征(VI)	0.65	0.12	0.10	1.68
	冠层结构特征+植被指数特征(CS+VI)	0.73	0.10	0.08	1.92
KNN	冠层结构特征(CS)	0.58	0.13	0.10	1.53
	植被指数特征(VI)	0.65	0.12	0.10	1.69
	冠层结构特征+植被指数特征(CS+VI)	0.68	0.11	0.09	1.77
GPR	冠层结构特征(CS)	0.50	0.14	0.11	1.41
	植被指数特征(VI)	0.66	0.12	0.10	1.73
	冠层结构特征+植被指数特征(CS+VI)	0.62	0.12	0.09	1.63
XGBoost	冠层结构特征(CS)	0.70	0.11	0.09	1.84
	植被指数特征(VI)	0.73	0.11	0.09	1.92
	冠层结构特征+植被指数特征(CS+VI)	0.74	0.10	0.08	1.97
AutoGluon	冠层结构特征(CS)	0.74	0.10	0.09	1.95
	植被指数特征(VI)	0.75	0.10	0.09	1.99
	冠层结构特征+植被指数特征(CS+VI)	0.78	0.09	0.08	2.15

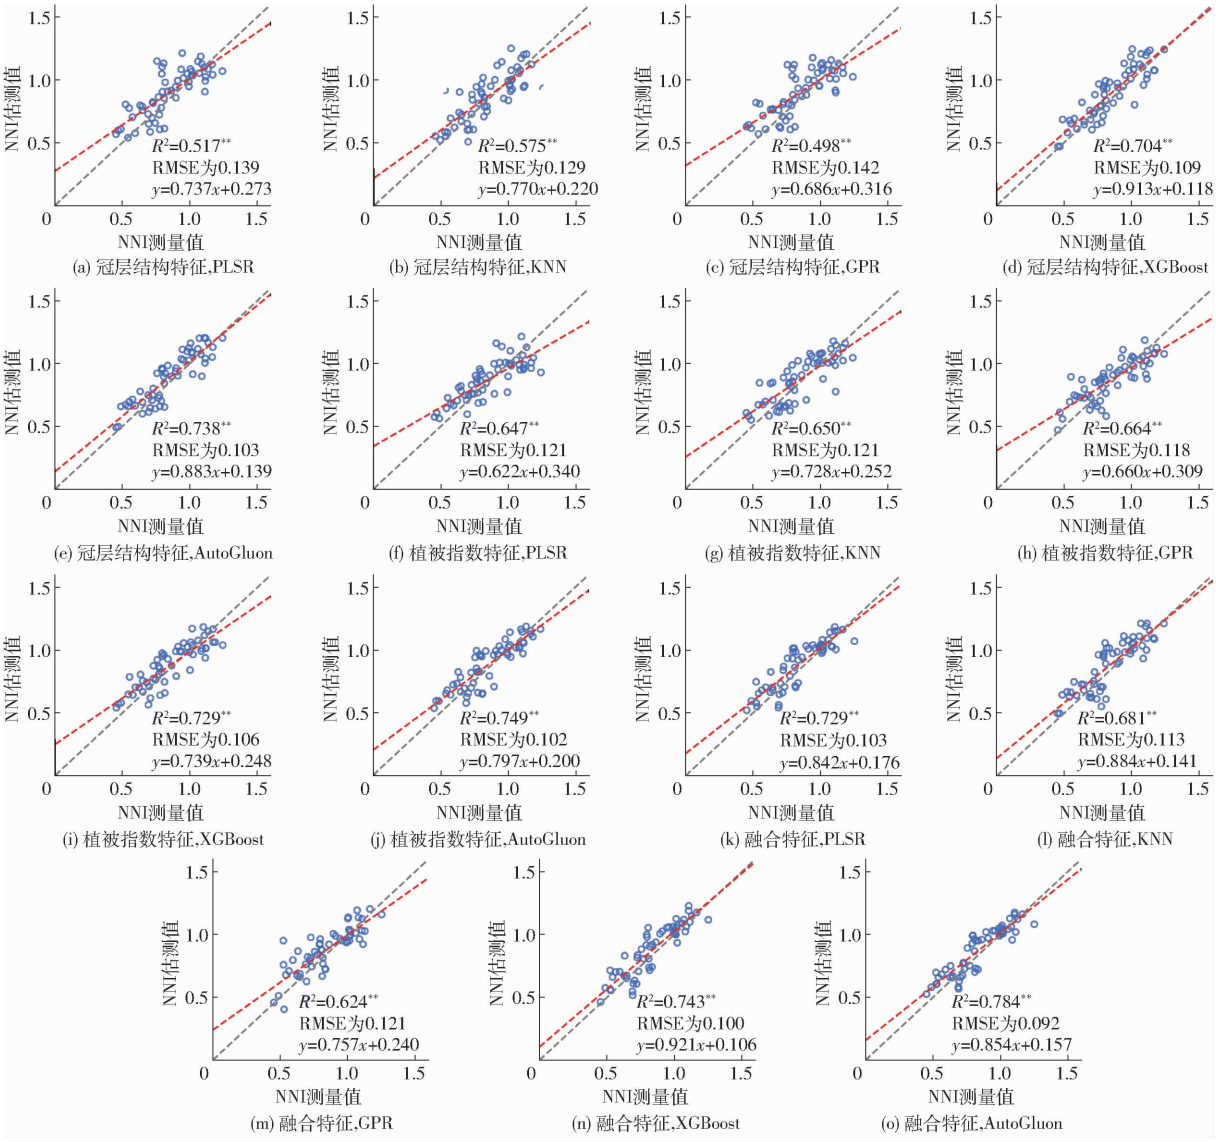

图 5 基于单特征及融合特征的模型散点图

Fig. 5 Model scatter plots based on single feature and fusion feature

表 4　基于 AutoGluon 模型的特征筛选消融实验结果

Tab. 4　Experimental results of feature screening ablation based on AutoGluon model

模型	特征变量	特征筛选方法	模型评估			
			R^2	RMSE	MAE	RPD
AutoGluon	冠层结构特征（CS）	SHAP	0.74	0.10	0.09	1.95
		Pearson	0.65	0.12	0.10	1.75
		无	0.62	0.13	0.10	1.63
	植被指数特征（VI）	SHAP	0.75	0.10	0.09	1.99
		Pearson	0.69	0.11	0.10	1.83
		无	0.58	0.14	0.11	1.55
	冠层结构特征 + 植被指数特征（CS + VI）	SHAP	0.78	0.09	0.08	2.15
		Pearson	0.72	0.11	0.09	1.93
		无	0.66	0.12	0.09	1.73

2.5　氮营养指数分布分析及处方图生成

通过比较不同特征组合的 NNI 估测模型，发现结合植被指数特征和冠层结构特征的 AutoGluon 模型取得了最佳效果。使用 AutoGluon 模型对实验田全地块进行估测，生成了 NNI 直方图（图 7a）并构建了 NNI 空间分布图（图 7b）。由于实验设置了氮肥梯度，直方图均呈现明显的多峰分布，NNI 空间分布可视化图也展现了明显的颜色差异，在低氮实验区域（N1、N2），冬小麦地块的 NNI 小于 0.8，施氮量为 N3 和 N4 的地块，NNI 值大部分大于 1.0，这表明合适的基肥与追肥可以显著提高冬小麦的氮营养水平。根据 NNI 分布计算出追肥处方图，结果如图 7c 所示，使用基于处方图指导的精准施肥方法，能够根

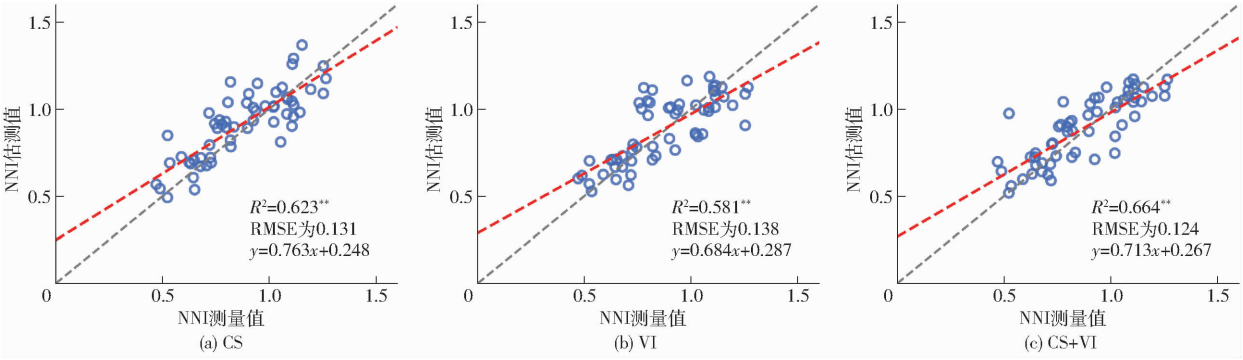

图 6　AutoGluon 模型在未筛选特征集上的预测散点图

Fig. 6　Scatter plots of AutoGluon model's performance predictions on unfiltered feature set

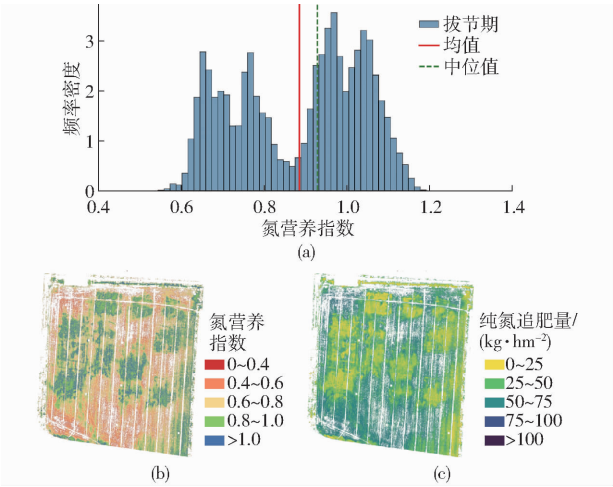

图 7　冬小麦拔节期氮营养指数分布分析

Fig. 7　Distribution analysis of nitrogen nutrition index (NNI) for winter wheat at jointing stage

据田间长势差异实现按需施肥，从而有效减少肥料的盲目投入，缓解过量施肥带来的污染风险。

3　讨论

建模结果受特征类别、筛选方法及模型选择的共同影响。本研究采用光谱与空间特征融合的方式，发现含近红外（NIR）波段的植被指数与 NNI 相关性更强，这主要由于氮素作为叶绿素的核心成分，其吸收与反射特性在 NIR 波段表现最为显著[34]。除光谱信息外，引入冠层结构特征能更直观地捕捉作物的空间变异性[35]。先前研究表明，由于不同特征间存在互补性，多特征组合相较于单一特征能显著提升估测精度[36]，本研究结论与此一致。

在特征筛选方面，本研究将通常用于可解释性分析的 SHAP 算法与递归消除思想结合[12]，以特征贡献度排名为筛选依据，通过遍历特征数量确定最优组合。相比传统方法，该算法能有效识别非线性贡献并权衡特征间的交互效应，提供量化的特征解释。消融实验证实，该方法在 3 类特征组合下均提升了回归精度。尽管计算复杂度较高，但在追求模型深度理解与高精度反演的场景中，其性能表现极具优势。

在模型选择上，本研究引入了自动机器学习模型，并与 4 个传统机器学习模型进行对比，验证结果表明，自动机器学习取得了最高的 R^2 值，值得注意的是，AutoML 的优势主要源于其模型集成与自动化超参数机制，使其在不同特征子集与不同时期之间表现出更小的性能波动与更高的上限；但相应地也带来更高的计算开销与训练时间。而一些传统模型

在特征筛选后的建模结果可以接近自动机器学习模型,这表明在样本规模较小或特征结构较为简单、先验充分的场景中,轻量模型依然具备应用价值。

虽然本研究提出的 NNI 回归建模及施肥决策方法具有较强的可解释性与估测精度,但仍存在一定局限性。首先,本研究目前仅聚焦于冬小麦拔节期。这主要是基于冬小麦的生理特性:拔节期是其氮素需求量最大的关键转折期,此时进行营养诊断并指导追肥,能显著提升化肥利用率。

4 结论

(1)揭示了遥感特征融合的增益机制并构建了高效特征筛选体系。采用基于 SHAP 算法与递归特征消除策略,从多源数据中精准提取了核心特征(CS + VI 23 个、CS 13 个、VI 11 个)。实验证实,不同维度特征具有显著的优势互补性,精度由高到低依次为 CS + VI、VI、CS;该筛选方法显著提升了建模效果,筛选后模型最高 R^2 达 0.78。

(2)确定了高精度的 AutoML 诊断模型。通过多算法对比验证,AutoGluon 模型在不同特征子集下的性能均优于传统模型。其在融合特征上模型效果达到最优(R^2 = 0.78、RMSE 为 0.09、RPD 为 2.15),表现出优异的预测稳定性与泛化能力,能够为冬小麦生长监测提供可靠的建模工具。

(3)本研究通过构建“特征优化-模型集成-诊断决策”的技术框架,有效解决了冬小麦氮营养诊断中特征冗余与模型精度低的问题。研究证实了遥感特征融合与 AutoML 在提升 NNI 估测精度上的有效性,对实现农田精准施肥及智能化田间管理具有重要的工程实践意义。

参 考 文 献

[1] Tilman D, Cassman K G, Matson P A, et al. Agricultural sustainability and intensive production practices[J]. Nature, 2002, 418(6898): 671 - 677.

[2] 冯海宽, 樊意广, 陶惠林, 等. 利用无人机高光谱影像的冬小麦氮含量监测[J]. 光谱学与光谱分析, 2023, 43(10): 3239 - 3246.
Feng Haikuan, Fan Yiguang, Tao Huilin, et al. Monitoring of nitrogen content in winter wheat based on UAV hyperspectral imagery[J]. Spectroscopy and Spectral Analysis, 2023, 43(10): 3239 - 3246. (in Chinese)

[3] Chen R, Zhu Y, Cao W, et al. A bibliometric analysis of research on plant critical dilution curve conducted between 1985 and 2019[J]. European Journal of Agronomy, 2021, 123: 126199.

[4] Maes W H, Steppe K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture[J]. Trends in Plant Science, 2019, 24(2): 152 - 164.

[5] 苏瑞东. 无人机在现代农业中的应用综述[J]. 江苏农业科学, 2019, 47(21): 75 - 79.
Su Ruidong. Application of UAVs in modern agriculture: a review[J]. Jiangsu Agricultural Sciences, 2019, 47(21): 75 - 79. (in Chinese)

[6] 齐浩, 孙海芳, 吕亮杰, 等. 基于无人机多光谱信息与纹理特征融合的小麦叶面积指数估测[J]. 农业机械学报, 2025, 56(3): 334 - 344.
Qi Hao, Sun Haifang, Lü Liangjie, et al. Wheat leaf area index estimation based on fusion of UAV multispectral information and texture features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 334 - 344. (in Chinese)

[7] Zhang S, Duan J, Qi X, et al. Combining spectrum, thermal, and texture features using machine learning algorithms for wheat nitrogen nutrient index estimation and model transferability analysis[J]. Computers and Electronics in Agriculture, 2024, 222: 109022.

[8] 郭燕, 井宇航, 王来刚, 等. 基于无人机影像特征的冬小麦植株氮含量预测及模型迁移能力分析[J]. 中国农业科学, 2023, 56(5): 850 - 865.
Guo Yan, Jing Yuhang, Wang Laigang, et al. UAV multispectral image-based nitrogen content prediction and the transferability analysis of the models in winter wheat plant[J]. Scientia Agricultura Sinica, 2023, 56(5): 850 - 865. (in Chinese)

[9] Nabwire S, Suh H K, Kim M S, et al. Review: application of artificial intelligence in phenomics[J]. Sensors, 2021, 21(13): 4363.

[10] Gill T, Gill S K, Saini D K, et al. A comprehensive review of high throughput phenotyping and machine learning for plant stress phenotyping[J]. Phenomics, 2022, 2(3): 156 - 183.

[11] He X, Zhao K, Chu X. AutoML: a survey of the state-of-the-art[J]. Knowledge-Based Systems, 2021, 212: 106622.

[12] 张宏鸣, 侯贵河, 孙志同, 等. 基于 XGBoost - Shapley 的玉米不同生育期 LAI 遥感估算[J]. 农业机械学报, 2022, 53(7): 208 - 216.
Zhang Hongming, Hou Guihe, Sun Zhitong, et al. Remote sensing estimation of maize leaf area index at different growth periods based on XGBoost - Shapley algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 208 - 216. (in Chinese)

[13] Zhang P, Lu B, Ge J, et al. Using UAV-based multispectral and RGB imagery to monitor above-ground biomass of oat-based

diversified cropping[J]. European Journal of Agronomy, 2025, 162: 127422.

[14] 郭燕, 王来刚, 贺佳, 等. 基于多层级特征筛选和无人机影像的冬小麦植株氮含量预测[J]. 农业工程学报, 2024, 40(12): 174 - 182.
Guo Yan, Wang Laigang, He Jia, et al. Predicting nitrogen content in winter wheat plants using multi-level sensitive feature filtering and UAV imagery[J]. Transactions of the CSAE, 2024, 40(12): 174 - 182. (in Chinese)

[15] Lundberg S M, Lee S I. A unified approach to interpreting model predictions[C]// Advances in Neural Information Processing Systems, 2017.

[16] Ulrich A. Physiological bases for assessing the nutritional requirements of plants[J]. Annual Review of Plant Biology, 1952, 3(3): 207 - 228.

[17] Lemaire G, Salette J, Sigogne M, et al. Relation entre dynamique de croissance et dynamique de prélèvement d'azote pour un peuplement de graminées fourragères. I. — Etude de l'effet du milieu[J]. Agronomie, 1984, 4(5): 423 - 430.

[18] 王晓玲. 长江中下游稻麦两熟区冬小麦植株器官临界氮浓度模型构建及氮素诊断调控研究[D]. 南京: 南京农业大学, 2017.
Wang Xiaoling. Study on construction of critical nitrogen concentration dilution models based on plant organs and diagnosis and regulation of wheat in the middle and lower reaches of the Yangtze River[D]. Nanjing: Nanjing Agricultural University, 2017. (in Chinese)

[19] Gitelson A A, Viña A, Ciganda V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005, 32(8): 2005GL022688.

[20] Hunt E R, Daughtry C S T, Eitel J U H, et al. Remote sensing leaf chlorophyll content using a visible band index[J]. Agronomy Journal, 2011, 103(4): 1090 - 1099.

[21] Ji Y, Liu Z, Liu R, et al. High-throughput phenotypic traits estimation of faba bean based on machine learning and drone-based multimodal data[J]. Computers and Electronics in Agriculture, 2024, 227: 109584.

[22] Rondeaux G, Steven M, Baret F. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of Environment, 1996, 55(2): 95 - 107.

[23] Sripada R P, Heiniger R W, White J G, et al. Aerial color infrared photography for determining early in-season nitrogen requirements in corn[J]. Agronomy Journal, 2006, 98(4): 968 - 977.

[24] Vincent L. Morphological grayscale reconstruction in image analysis: applications and efficient algorithms[J]. IEEE Transactions on Image Processing, 1993, 2(2): 176 - 201.

[25] Gitelson A A, Gritz Y, Merzlyak M N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves[J]. Journal of Plant Physiology, 2003, 160(3): 271 - 282.

[26] Dash J, Curran P J. The MERIS terrestrial chlorophyll index[J]. International Journal of Remote Sensing, 2004, 25(23): 5403 - 5413.

[27] Daughtry C S T, Gallo K P, Goward S N, et al. Spectral estimates of absorbed radiation and phytomass production in corn and soybean canopies[J]. Remote Sensing of Environment, 1992, 39(2): 141 - 152.

[28] Geladi P, Kowalski B R. Partial least-squares regression: a tutorial[J]. Analytica Chimica Acta, 1986, 185: 1 - 17.

[29] Guo G, Wang H, Bell D, et al. KNN model-based approach in classification[C]// On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE. Berlin, Heidelberg: Springer, 2003: 986 - 996.

[30] Schulz E, Speekenbrink M, Krause A. A tutorial on gaussian process regression: modelling, exploring, and exploiting functions[J]. Journal of Mathematical Psychology, 2018, 85: 1 - 16.

[31] Chen T, Guestrin C. XGBoost: a scalable tree boosting system[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, California, USA: ACM, 2016: 785 - 794.

[32] Erickson N, Mueller J, Shirkov A, et al. AutoGluon-Tabular: robust and accurate AutoML for structured data[PP/OL]. V1. arXiv (2020 - 03 - 13)[2026 - 02 - 04]. https://doi.org/10.48550/arxiv.2003.06505.

[33] Kennedy J, Eberhart R. Particle swarm optimization[C]// Proceedings of ICNN'95-International Conference on Neural Networks. Perth, WA, Australia: IEEE, 1995: 1942 - 1948.

[34] Feng Z, Guan H, Yang T, et al. Estimating the canopy chlorophyll content of winter wheat under nitrogen deficiency and powdery mildew stress using machine learning[J]. Computers and Electronics in Agriculture, 2023, 211: 107989.

[35] Castilho Silva D, Emoke Madari B, Santana Carvalho M da C, et al. Optimizing nitrogen estimates in common bean canopies throughout key growth stages via spectral and textural data from unmanned aerial vehicle multispectral imagery[J]. European Journal of Agronomy, 2025, 169: 127697.

[36] 樊杰杰, 樊意广, 马彦鹏, 等. 基于无人机多源遥感信息融合的冬小麦叶片氮素含量监测方法[J]. 农业机械学报, 2026, 57(11): 314 - 324.
Fan Jiejie, Fan Yiguang, Ma Yanpeng, et al. Monitoring method for winter wheat leaf nitrogen content based on UAV multi-source remote sensing fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(11): 314 - 324. (in Chinese)