基于无人机多光谱影像和机器学习的水稻产量与氮素利用率预测

刘吉凯^{1,2},王伟强¹,苏祥祥¹,李 军¹,年 颖¹,祝雪晴¹, 马 强¹,李新伟^{1,2,3*}

(1. 安徽科技学院资源与环境学院,滁州 233100; 2. 安徽省作物智慧种植与加工技术工程研究中心,滁州 233100;3. 安徽省功能农业与功能食品重点实验室,滁州 239000)

摘 要:为了筛选对产量与氮素利用率(nitrogen use efficiency, NUE)敏感的遥感特征,构建准确的产量及 NUE 预测 模型,该研究开展为期 2a 的多氮素水平与多水稻品种田间试验,获取了 3 个关键生长阶段的无人机(unmanned aerial vehicle, UAV)多光谱影像,采用递归特征消除(recursive feature elimination, RFE)算法筛选敏感植被指数(vegetation indices, VIs)、纹理特征(texture features, TFs)和二者的混合特征,利用 6 种机器学习算法构建"敏感特征-产量和 NUE"直接预测模型,并根据 NUE 属性提出一种"敏感特征-产量-NUE"间接预测模型,通过两种模型的对比验证了 UAV 在水稻 NUE 精确预测中的应用潜力。研究结果表明:(1)尽管对产量和 NUE 敏感的特征因生长阶段而异,但 DVI (difference vegetation index)、VARI (visible atmospherically resistant indices)和 mNDblue(modified normalized difference blue index)以及纹理均值(Mean)在多个生长阶段对产量敏感;repRVI(reciprocal ratio vegetation index)、 相关性(correlation, Cor)和 Mean在多个生长阶段对 NUE 敏感。(2)深度神经网络(deep neural network, DNN)模型 对产量和 NUE 直接预测性能最佳。在灌浆期,基于 TFs 的产量预测精度最高(R^2 =0.938, RMSE=479.591 kg/hm²);在 分蘖期,基于混合特征的 NUE 预测精度最佳,农学氮素利用率(agronomic nitrogen use efficiency, aNUE)和氮素偏生产 力(nitrogen partial factor productivity, NPFP)的预测精度分别为 R^2 =0.711, RMSE=4.448 kg/kg 和 R^2 =0.781, RMSE= 12.787 kg/kg。(3)与直接预测模型相比,间接预测模型对 NUE 预测精度更高,对 aNUE 和 NPFP 的预测 R^2 分别提高 了 18.589%和 14.733%, RMSE 分别降低了 54.411%和 90.015%。研究结果可为田块尺度下利用无人机遥感技术快速准 确预测水稻产量和 NUE 提供新思路。

关键词: 无人机; 多光谱; 产量; 氮素利用率; 间接预测; 机器学习 doi: 10.11975/j.issn.1002-6819.202411236 中图分类号: S126 文献标志码: A 文章编号: 1002-6819(2025)-08-0387-12

刘吉凯,王伟强,苏祥祥,等.基于无人机多光谱影像和机器学习的水稻产量与氮素利用率预测[J].农业工程学报,2025,41(8):387-398.doi:10.11975/j.issn.1002-6819.202411236 http://www.tcsae.org

LIU Jikai, WANG weiqiang, SU Xiangxiang, et al. Prediction of rice yield and nitrogen use efficiency based on UAV multispectral imaging and machine learning[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(8): 387-398. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202411236 http:// www.tcsae.org

0 引 言

水稻是全球三大粮食作物之一^[1],中国是全球最大的水稻生产国,种植面积占全球总面积的20%,产量占 全球总产量的30%(联合国粮食与农业组织,2023)。 氮素(nitrogen,N)是水稻生长所必需的关键营养元素, 对水稻的生长、产量及品质起至关重要的作用^[2]。传统 稻作系统倾向于大规模施用氮肥,过量施肥会降低氮肥 利用,增加农业生产成本,并导致环境污染^[3-4]。因此,

收稿日期: 2024-11-28 修订日期: 2025-03-20

※通信作者: 李新伟,博士,副教授,研究方向为农业遥感。 Email: lixw@ahstu.edu.cn 及时准确地评估稻田氮肥利用对优化氮肥管理、促进水 稻健康生长及推动农业绿色发展具有重要意义。

氮素利用率(nitrogen use efficiency, NUE)是衡量 作物生长发育进程中氮素吸收与利用状况的重要指标, 广泛应用于碳—氮循环和施肥管理中^[5]。常用的作物 NUE 评价指标包括氮素表观回收率(nitrogen apparent recovery fraction, NARF)、氮素吸收效率(nitrogen uptake efficiency, NUpE)、氮素利用效率(nitrogen utilization efficiency, NUtE)、农学氮素利用率 (agronomic nitrogen use efficiency, aNUE)和氮素偏生 产力(nitrogen partial factor productivity, NPFP)等^[5-6]。 传统 NUE 评价方法往往采取破坏性取样,或需作物成熟 收割后才能确定,无法满足当前精准农业中无损、实时、 快速、高效的田间预测需求^[7]。

遥感技术的快速发展使得作物生长参数的无损监测成为可能^图。无人机(unmanned aerial vehicle, UAV)遥 感技术因其灵活性、机动性及性价比高等优势,在 NUE

基金项目:安徽省高等学校科学研究项目(2023AH051855;2022AH051623); 安徽省作物智慧种植与加工技术工程研究中心开放课题(ZHKF03);安徽省高校理工科教师赴企业挂职实践计划项目(224jsqygz62)

作者简介: 刘吉凯,博士生,研究方向为麦类作物生长无人机遥感监测。 Email: liujk@ahstu.edu.cn

预测中展现了巨大的潜力^[9-12]。例如,YANG 等^[13]利用 无人机多光谱影像预测冬小麦的 aNUE,发现归一化红 边植被指数(normalized difference rededge index, NDRE) 能较好地预测 aNUE。LIU 等^[4]利用无人机多光谱影像 评估了冬小麦多个生长阶段的 aNUE 和 NPFP,结果表 明基于最佳植被指数的多元线性模型可实现 NUE 的快速 预测。

当前,NUE预测主要依赖于植被指数(vegetation indices, VIs)^[4,12-15],但VIs易受土壤背景和冠层密度的 影响。为解决这一问题,纹理特征(texture Features, TFs) 被用以提高 NUE 预测的准确性和适用性^[2,8,10],然而, TFs在 NUE 预测中的应用仍然有限^[11]。此外,随着特征 数量的增加,简单模型难以处理高维特征,导致预测效 果不佳^[16]。特征选择(features selection, FS)结合机器 学习(machine learning, ML)技术可以筛选与因变量密 切相关的遥感特征,能够学习特征与因变量之间复杂的 非线性关系,从而显著提升预测精度^[17]。目前,随机森 林(random fores, RF)、支持向量机(support vector machines, SVM)、深度神经网络(deep neural network, DNN)等 ML方法已广泛应用于农业遥感任务^[2,7,14,16,18], 但 ML 在 NUE 预测中的应用尚未见相关研究报道。

从数学角度来看,NUE 可以通过关键中间变量(产量、氮含量和生物量等)计算得到。鉴于这些关键变量 可以通过无人机遥感技术实现高精度预测,本文提出一 种针对 NUE 的间接预测方式——"敏感特征-产量-NUE"模型。然而,目前尚未有基于间接模型的 NUE 预 测研究,其预测精度能否达到"敏感特征-NUE"直接预 测模型的精度仍不明确。

综上,本文开展多氮肥处理与多水稻品种的 2a 田间 试验,利用无人机平台获取水稻关键生长阶段的冠层多 光谱影像,拟结合 VIs 和 TFs,实现对水稻产量及 NUE 的高精度预测,具体目标为:(1)筛选适用于水稻产量 与 NUE 预 测 的 敏 感 VIs、TFs 及 其 混 合 特 征; (2)评估不同 ML 算法对产量和 NUE 的预测潜力;

(3)对比基于敏感特征的 NUE 直接预测与以产量为中 间变量的间接预测模型的结果差异。研究旨在探索无人 机多光谱影像对产量和 NUE 的预测潜力,并根据 NUE 的属性提出一种有效、便捷、可靠的间接预测模式,为栽 培和育种研究中作物健康生长和营养管理决策提供参考。

1 材料与方法

1.1 研究区概况与试验设计

研究区位于安徽省滁州市凤阳县小岗村(117°46'7"E, 32°48'52"N)(图 1a),属典型的暖温带季风大陆性气 候区,年均温度15.4℃,年均降水量1050mm,年均日 照时长2073.4h。2020年试验采用随机区组裂区设计, 以4个氮梯度为主区,3个水稻品种为裂区,3次重复, 共36个小区,小区大小为2m×8m(图 1b)。4个氮 处理分别为:N0(不施氮)、N100(100 kg/hm²)、 N200(200 kg/hm²)、N300(300 kg/hm²);3个水稻品 种为润珠香占V1、润珠银占V2和红香糯V3。因农田 改造,2022年试验地向东平移40m,氮处理与2020年 相同,但水稻品种仅有 2 个: 润珠香占 V1 和晶两优华 占 V4,5 次重复,共 40 个小区,小区大小为 2 m × 5 m (图 lc)。氮肥(尿素,含有效 N 46%)分 3 次施 用,比例为基肥:拔节肥:穗肥=4:3:3。



注: N0~N300 分别代表纯氮含量为 0、100、200 和 300 kg·hm⁻² 的氮 处理。

Note:N0-N300 represent nitrogen treatments with pure nitrogen content of 0, 100, 200 and 300 kg·hm⁻², respectively

图 1 研究区地理位置与试验设计

Fig.1 Geographical location of study area and experimental design

1.2 无人机数据获取与预处理

1.2.1 无人机影像获取

利用 DJI Phantom 4 MultiSpectral (P4M) 无人机平 台获取水稻 3 个生长阶段的多光谱影像,分别为分蘖期 (tillering stage, TS) (2020 年 7 月 25 日和 2022 年 7 月 28 日)、抽穗期 (heading stage, HS) (2020 年 8 月 23 日和 2022 年 8 月 24 日)与灌浆期 (filling stage, FS) (2020 年 9 月 20 日和 2022 年 9 月 24 日)。P4M 内置 5 个多光谱传感器,中心波长与带宽分别是 450 ± 16 nm (蓝), 560 ±16 nm (红), 730 ±16 nm (红边)和 840 ±26 nm (近红外), 分辨率为 208 万像素。

采用 DJI GS PRO 软件设定飞行参数与航拍路线。 于当地时间的 10:00—13:00,选择晴朗、无风少云的 日期进行航拍作业,飞行高度设为 30 m,飞行速度设为 2.0 m/s,等时间间隔拍照(2 s),自动曝光,航向重叠 度 90%,旁向重叠度 85%。

1.2.2 无人机影像预处理

采用 Pix4Dmapper 软件进行拼接重建,依次执行相

机参数/坐标系统设置、初始化处理、点云及纹理处理和 正射影像生成。利用 ENVI 软件的 layer stacking 工具将 拼接好的单波段影像合并成多光谱文件(.tiff),统一坐 标系为 WGS 84 UTM 50N,空间分辨率统一重采样为 1.5 cm。采用经验线性模型^[10,19]进行辐射定标,通过预 先铺设在无人机视野内的已知反射率的标准参考板,将 原始图像的数值(digital number, DN)转换为反射率值。

对多个时期影像执行相对几何校正,以消除几何位 置偏移对影像分析的影响。以抽穗期影像为基准,在 ArcMap软件中按照二次多项式和最邻近重采样对分蘖期 和灌浆期获取的影像进行地理配准,配准精度小于2个 像素。

1.3 田间农学数据获取与预处理

水稻成熟时,在每个小区选择3处长势均匀且有代表性的0.3m×0.3m区域进行收割,剪穗后带回实验室脱粒,籽粒晒至恒定质量后称量,产量统一换算至标准单位 kg/hm²。

按照式(1)和式(2)计算农学氮素利用率(aNUE) 和氮素偏生产力(NPFP)。

$$aNUE = \frac{GY_{N_f} - GY_{N_0}}{N_f}$$
(1)

$$NPFP = \frac{GY_{N_f}}{N_f}$$
(2)

式中 GY_{N_f} 和 GY_{N0} 分别为不同氮处理区的水稻籽粒产量, 单位为 kg/hm², N_f 代表各处理的施氮量,单位为 kg/hm²。

1.4 特征提取

1.4.1 植被指数

VIs 是波段反射率值的线性或非线性组合,在增强 感兴趣信号同时能有效抑制田间水土背景、大气散射、 光照扰动和环境差异等带来的噪声。本文选择 18 个用于 产量和 NUE 预测的 VIs,具体见表 1。

1.4.2 纹理特征

利用灰度共生矩阵 (gray-level co-occurrence matrix, GLCM) 对多光谱影像的主成分波段 1 和 2 (累积方差 贡献率大于 90%) 进行纹理特征 (TFs) 提取,参考文 献 [10],将窗口大小为 3 × 3,方向为 45°,步长设置为 1。每个主成分可提取 8 个 TFs,分别是均值 (mean, Mean)、方差 (variance, Var)、均匀性 (homogeneity, Hom)、对比度 (contrast, Con)、非相似性 (dissimilarity, Dis)、信息熵 (entropy, Ent)、二阶矩 (second moment, SM) 和相关性 (correlation, Cor),共 计 16 个指标。根据主成分与 TFs 的组合进行命名,如 PC1Mean 代表基于第一主成分的 Mean 指标, PC2Cor 代 表基于第二主成分的 Cor 指标。

1.5 模型构建与验证

1.5.1 敏感特征筛选

特征筛选(FS)可以从原始特征集中去除不相关和 冗余的特征,通过聚焦信息丰富的少量敏感特征,实现 更高的预测精度、更好的泛化能力和更少的建模成本^[25]。 本文利用基于随机森林(RF)模型的递归特征消除 (recursive feature elimination, RFE)算法选择对水稻产 量与 NUE 敏感的特征^[7,22]。

表 1 本文使用的植被指数 Table 1 Vegetation indices(VIs) used in this study

植被指数 (VIs)	方程 Equations	文献
也改旧奴(113)	为小王 Equations	References
归一化植被指数(NDVI)	(nir - red)/(nir + red)	[20]
红边归一化指数(NDRE)	(nir - rededge)/(nir + rededge)	[20]
叶面叶绿素指数(LCI)	(nir - rededge)/(nir + red)	[20]
绿色归一化植被指数 (GNDVI)	(nir - green)/(nir + green)	[20]
比值植被指数(RVI)	nir/red	[20]
差值植被指数(DVI)	nir – red	[20]
红边叶绿素指数 (CIrededge)	nir/rededge – 1	[20]
土壤调整指标植被指数 (SAVI)	$\frac{1.5 \times (nir - red)}{nir + red + 0.5}$	[20]
优化型土壤调整植被指数 (OSAVI)	$\frac{1.16 \times (nir - red)}{nir + red + 0.16}$	[20]
修正型土壤调整植被指数 (MSAVI)	$\frac{((2\times nir+1)-((2\times nir+1)^2-8\times (nir-red)))}{2}$	[21]
绿色土壤调整植被指数 (GSAVI)	$\frac{1.5 \times (nir - green)}{nir + green + 0.5}$	[22]
增强植被指数(EVI)	$\frac{2.5 \times (nir - red)}{nir + 6 \times red - 7.5 \times blue + 1}$	[20]
可见光大气阻抗指数 (VARI)	(green – red)/(green + red – blue)	[4]
可见光大气阻抗红边指数 (VARIre)	$\frac{rededge - 1.7 \times red + 0.7 \times blue}{rededge + 2.3 \times red - 1.3 \times blue}$	[23]
MERIS 陆地叶绿素指数 (MTCI)	(nir – rededge)/(rededge – red)	[4]
修正型归一化差值蓝光指数 (mNDblue)	(blue - rededge)/(blue + nir)	[4]
植被近红外反射率(NIRv)	NDVI× <i>nir</i>	[24]
倒比值植被指数(repRVI)	red/nir	[4]

注: blue, green, red, rededge 和 nir 分别表示多光谱影像的蓝光波段、绿光波段、红光波段、红边波段和近红外波段的反射率。

Note: *blue*, green, *red*, *rededge* and *nir* reflect the reflectance of the blue light, green light, red light, rededge, and near-infrared bands of multispectral image, respectively.

1.5.2 "敏感特征-产量和 NUE"直接预测模型

采用 RF^[10]、支持向量机(SVM)^[25]、多层感知机 (multilayer perceptron, MLP)^[26]、梯度提升机(gradient boosting machine, GBM)^[27]、深度神经网络(DNN)^[28-29] 和长短期记忆网络(long short-term memory, LSTM)^[30-31] 6种机器学习(ML)算法分别对特征筛选后的 VIs 子集、 TFs 子集及其混合特征子集进行产量和 NUE 的预测(图 2a)。 本文使用网格调参对前 5 种 ML 模型的超参数进行优化: RF 模型中,随机选择的特征数量(mtry)取值范围为 1~10,决策树数量(ntree)取值范围为 500~1 000,最小 叶子节点数量 (min n) 取值范围为 2~10; SVM 模型中, 正则化参数 (cost) 取值范围为 0.001~10, 径向基函数核 参数(sigma)取值范围为 0.001~1。MLP 模型中, 隐藏 层的神经元数量(hidden units)取值范围为 5~50,惩罚 系数(penalty)取值范围为0.001~1,迭代次数(epochs) 取值范围为 50~200; GBM 模型中,决策树数量 (ntree) 取值范围为 100~2000, 树深度(depth) 取值范围为 2~10, 学习率(shrinkage)取值范围为 0.001~1, 叶子结 点最小样本数(minobsinnode)取值范围为 5~50; DNN 模型中,隐藏层层数(hidden)取值范围为 2~4,神经元 数量(units)取值范围为 32~256,激活函数(activation)

取值为 rectifier、rectifierwithdropout、tanh 和 maxout, 丢弃率(dropout)取值范围为 0~0.2,正则化(11)取值 范围为 0~0.001,学习率(rate)取值范围为 0.001~0.01。 因样本量偏小,LSTM 采用固定结构和超参数取值,具 体为:隐藏层神经元数量(units)为 32,丢弃率 (dropout)为 0.2,全连接层神经元数量(dense)为 16, 激活函数(activation)为 relu,迭代次数(epochs)为 500,优化器(optimizer)为 adam,损失函数(loss)为 均方误差(MSE)。



注: VIs 和 TFs 分别为植被指数和纹理特征; RF、SVM、MLP、GBM、 DNN 和 LSTM 分别为随机森林、支持向量机、多层感知机、梯度提升机、 深度神经网络和长短期记忆网络模型; Yield、aNUE 和 NPFP 分别为产量、 农学氮素利用率和氮素偏生产力。

Note:VIs and TFs denote vegetation indices and texture features respectively; RF, SVM, MLP, GBM, DNN, and LSTM represent random forest, support vector machine, multilayer perceptron, gradient boosting machine, deep neural network, and long short-term memory models respectively; Yield, aNUE, and NPFP correspond to gain yield, agricultural nitrogen use efficiency, and nitrogen partial factor productivity respectively.

图 2 产量和氮素利用率直接与间接预测模型

Fig.2 Direct and indirect prediction models for yield and NUE

1.5.3 "敏感特征-产量-NUE"间接预测模型

构建如图 2b 所示的"敏感特征-产量-NUE"间接预测模型。该模型首先利用上述 6 种 ML 算法进行产量预测,筛选最佳算法并得到预测产量,之后再通过式(1)和式(2)计算获得 aNUE 和 NPFP。间接预测模型通过 产量搭建敏感遥感特征与氮素利用率的桥梁,其精准度 完全取决于产量预测精度。与传统的数理计算相比,间 接预测模型将 NUE 评价适用期由成熟期拓展到整个生长 阶段,可更好地解释水稻生长过程中的 NUE 变化与及其 影响因素,有助于在生长早期筛选氮高效水稻品种。 1.5.4 模型精度验证

为避免样本选择的随机性,保证模型的稳定性和可 靠性,RFE和6种ML回归模型重复执行50次,每次选 择不同的随机采样数,取50次评价指标的平均值作为模 型输入特征子集选择及ML模型性能判断依据。每次执 行时随机选择70%的样本用作训练集建立模型,剩余的 30%样本用作模型性能评估的测试集。模型评价指标采 用决定系数(coefficient of determination, *R*²)和均方根误 差(root mean square error, RMSE),计算式如下:

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (x_{i} - y_{i})^{2}}{\sum_{i=1}^{n} (x_{i} - \bar{x})^{2}}$$
(3)

RMSE =
$$\sqrt{\frac{\sum_{i=1}^{n} (x_i - y_i)^2}{n}}$$
 (4)

式中*x_i和y_i*分别为第*i*个样本的实测值和模型预测值; *x*为 实测样本值的平均值; *n*为样本数量。

采用评价指标从测试集到训练集的变化率评价模型 的均衡性,计算式如下:

$$\Delta R^2 = \frac{(R^2_{testing} - R^2_{training})}{R^2_{training}} \times 100\%$$
(5)

$$\Delta \text{RMSE} = \frac{(\text{RMSE}_{testing} - \text{RMSE}_{training})}{\text{RMSE}_{training}} \times 100\%$$
(6)

式中 ΔR^2 和 $\Delta RMSE$ 分别为 R^2 和 RMSE的变化率; $R^2_{testing}$ 和 $R^2_{training}$ 分别为模型在测试集与训练集上的 R^2 ; RMSE_{testing}和RMSE_{training}分别为模型在测试集与训练集上的RMSE。

2 结果与分析

2.1 产量与 NUE 的敏感特征筛选

利用 RFE 算法分别对 VIs、TFs 和二者的混合集进 行筛选,结果见图 3。根据筛选数量与 50 次循环选择结 果的频数分布,确定敏感 VIs 子集、TFs 子集和混合特 征子集,结果见表 2。由表 2 可知,不同生长阶段的敏 感特征间存在明显的差异,由此导致在不同生长阶段, 基于不同输入特征的模型性能差异。混合特征的筛选结 果并不是单一特征筛选的集合,说明 VIs 和 TFs 的敏感 特征间存在互相关,可能会影响模型的性能。需要注意 的是,对于混合特征,TFs 的比重随水稻生长发育增加, 表明在水稻生长的中后期引入空间纹理信息有利于弥补 VIs 的缺陷,可保证模型的预测精度与稳定性。

2.2 基于"敏感特征-产量"模型的产量预测

产量预测效果受回归算法、生长发育阶段和模型输 入特征的影响(表 3)。LSTM 模型在 3个生长阶段存 在不同程度的欠拟合,GBM、RF、MLP 和 SVM 则存在 过拟合。RF和 GBM 模型对产量的预测精度在 3个生长 阶段相当, SVM 模型在抽穗期和灌浆期的预测性能较低, MLP 模型的预测精度最差。除 DNN 模型外,其余模型 在分蘖期与抽穗期时的预测性能差异较小,且高于灌浆 期时的预测精度。综合模型在训练集与测试集上的均衡 性, DNN 模型表现最佳, R^2 为 0.748~0.938, ΔR^2 为 2.033%~7.195 %; RMSE 为 969.333~479.591 kg/hm², ΔRMSE 为-2.644%~2.952%。在灌浆期 DNN 模型对产 量的预测效果最优,且在纹理特征子集上精度最高, R²=0.938, RMSE=479.591 kg/hm²。基于最佳模型进行产 量预测,实测值和预测值的关系见图 4a。线性模型的 R²=0.940, RMSE=166.981 kg/hm², 达到 0.01 水平显著 性差异。DNN 模型对中低值水平(<7000 kg/hm²)的产 量具有较好的预测效果,但是对高值水平(>9000 kg/hm²) 的产量存在高估。



注: 红绿蓝实线段分别表示分蘖期、抽穗期和灌浆期时执行 50 次 RFE 特征筛选结果的均值,对应颜色的阴影带表示 50 次筛选结果的范围. Note: The red, green, and blue solid lines represent the mean values of 50 RFE feature selection results performed during the tillering, heading, and filling stages, respectively. The shaded areas corresponding to these colors indicate the range of the 50 selection results.

图 3 不同生长阶段的敏感特征筛选结果 Fig.3 Screening results of sensitive features at different growth stages

2.3 基于直接与间接模型的水稻氮素利用率预测

2.3.1 基于"敏感特征-NUE"模型的 NUE 直接预测

利用 6 种 ML 算法,基于筛选的敏感特征进行 aNUE 和 NPFP 预测,结果见表 4 和表 5。对于 aNUE, ML 模型在 3 个阶段均存在不同程度的过拟合。DNN 和 LSTM 模型相较于其他模型具有明显优势。综合模型在 训练集与测试集上的平衡性,DNN 模型的性能在所有生 长阶段与特征集上均表现最佳, R^2 为0.367~0.711, ΔR^2 为-7.027%~ 10.444%; RMSE 为 4.448~ 6.604 kg/kg, Δ RMSE 为 -3.541%~ 5.634%。基于混合特征子集的 DNN 模型在 3 个生长阶段对 aNUE 的预测效果均优于光 谱和纹理特征子集。在分蘖期模型的预测效果最佳, R^2 =0.711, RMSE=4.448 kg/kg。 对于 NPFP, GBM、RF、MLP 和 SVM 存在明显的 过拟合。随着生长阶段推进,模型的预测性能逐步下降。 在分蘖期,DNN、GBM、MLP、RF 和 SVM 模型的预 测精度相当;在抽穗期和灌浆期,DNN、LSTM 和 MLP 模型的预测性能相似,RF、GBM 和 SVM 模型的 预测性能较差。DNN 算法在训练集与测试集上的性能 最均衡, R^2 为0.377~0.781, ΔR^2 为-4.930%~17.951%; RMSE 为 21.019~12.787 kg/kg, Δ RMSE 为 -1.500%~ 12.712%。与 aNUE 相似,在分蘖期基于混合特征子集 的 DNN 模型的预测效果最佳, R^2 =0.781, RMSE= 12.787 kg/kg。

基于最佳模型对 aNUE 和 NPFP 进行预测,实测值 和 预测值的对比见图 4。线性模型的精度分别为

*R*²=0.737, RMSE=3.117 kg/kg 和 *R*²=0.862, RMSE= 9.054 kg/kg,均达到 0.01 水平显著性差异。值得注意的

是, 2个 DNN 预测模型均存在"低值高估"与"高值低估"现象。

表 2 RFE 算法筛选出的敏感特征

Table 2 Sensitive features selected by the RFE algorithm

时期 Stages	目标 Objects	VIs	TFs	VIs+TFs		
	产量	DVI、mNDblue、repRVI、EVI、VARI、SAVI、 OSAVI 和 NIRv	PC1Mean 和 PC2Mean	DVI、mNDblue、PC2Mean、repRVI、VARI、EVI、 VARIre 和 SAVI		
分蘖期 Tillering stage	aNUE	repRVI、GNDVI、DVI、EVI、GSAVI、NIRv、 MTCI、OSAVI、SAVI、VARIre、CIrededge、 NDRE 和 NDVI	PC1Cor、PC1Mean、PC2Mean 和 PC2Cor	DVI、EVI、NIRv、PC1Cor、PC1Mean、PC2Cor、 PC2Mean、repRVI、SAVI、GSAVI、GNDVI、 OSAVI、VARIre 和 MTCI		
	NPFP	repRVI、CIrededge、LCI、GNDVI和NDRE	PC1Cor、PC1Mean、PC2Cor、 PC2Mean、PC2SM 和 PC2Hom	mNDblue、MTCI、PC1Cor、PC1Mean、PC2Cor、 PC2Mean、repRVI、LCI、NDRE、CIrededge 和 DVI		
抽穗期 Heading stage 灌浆期 Filling stage	产量	CIrededge、DVI、EVI、GNDVI、GSAVI、LCI mNDblue、MSAVI、MTCI、NDRE、NIRv、 OSAVI、repRVI、SAVI、VARI 和 VARIre	、PC1Mean、PC2Cor和PC2Mean	PC1Mean、PC2Cor、PC2Mean、MTCI、mNDblue、 CIrededge 和 NDRE		
	aNUE	DVI、EVI、GSAVI、NDVI、repRVI、RVI、 VARI、VARIre、mNDblue、SAVI、NIRv、 MSAVI 和 OSAVI	PC2Mean、PC1Cor 和 PC1Mean	NDVI、PC1Cor、PC2Cor、repRVI、RVI、VARI、 VARIre、GNDVI、PC1Hom、PC1Mean、PC1Con、 PC1Dis、PC1Var 和 PC2Hom		
	NPFP	DVI、GSAVI、mNDblue、NDVI、repRVI、 RVI、VARI、VARIre、NIRv、SAVI和MTCI	PC1Cor、PC1Mean 和 PC2Mean	mNDblue、NDVI、PC1Cor、PC1Hom、repRVI、 RVI、VARI、VARIre、PC1Dis、PC1Var、 PC1Con、GSAVI和PC2Cor		
	产量	CIrededge、mNDblue、MTCI、NDRE、LCI、 VARI、DVI、GNDVI和 VARIre	PC1Mean、PC2Mean、PC2Con、 PC2Dis、PC2Hom、PC1Con、 PC2Var、PC1Dis、PC1Var、 PC2Cor 和 PC2Ent	PC1Con、PC1Mean、PC2Con、PC2Dis、PC2Hom、 PC2Mean、PC2Var、VARI、VARIre、PC2SM、 EVI、GNDVI、PC2Cor、PC2Ent、PC1Dis、 PC1Var、PC1Cor、repRVI、MTCI和OSAVI		
	aNUE	GNDVI、VARIre、repRVI、CIrededge、LCI、 mNDblue、NDRE、MTCI、NDVI、RVI、 VARI、OSAVI、GSAVI、MSAVI、DVI、 SAVI、NIRv和EVI	PC1Con、PC1Cor、PC1Dis、 PC1Hom、PC1Mean、PC1Var、 PC2SM 和 PC2Ent	PC1Con、PC1Dis、PC1Hom、PC1Mean、PC1Var、 VARIre、GNDVI 和 repRVI		
	NPFP	CIrededge、GNDVI、LCI、mNDblue、MTCI、 NDRE、NDVI、OSAVI、repRVI、RVI、VARI 和 VARIre	PC1Con、PC1Cor、PC1Dis、 PC1Hom、PC1Mean、PC1Var、 PC2SM 和 PC2Ent	GNDVI、MTCI、PC1Con、PC1Dis、PC1Hom、 PC1Mean、PC1Var、VARIre、repRVI、CIrededge、 LCI、mNDblue、NDRE 和 VARI		

表 3 基于直接预测模型的产量预测结果

Table 3 Results of the yield prediction based on direct prediction models

		分蘖期 Tillering stage					抽穗期 Heading stage				灌浆期 Filling stage			
特征	模型		测试集	变	化率		测试集	变	化率		测试集	变	化率	
Features	Models		Testing set	Chan	ged / %		Testing set	Chan	ged / %		Testing set	Chang	ged / %	
		R^2	RMSE / (kg·hm ⁻²)	ΔR^2	ΔRMSE	R^2	RMSE / (kg·hm ⁻²)	ΔR^2	ΔRMSE	R^2	RMSE / (kg·hm ⁻²)	ΔR^2	ΔRMSE	
	LSTM	0.70	1 087.80	30.02	8.74	0.73	1 047.96	21.72	13.43	0.73	1 031.69	15.97	16.91	
	GBM	0.74	941.21	-20.13	73.64	0.68	1 031.72	-31.49	905.38	0.65	1 087.12	-23.18	44.28	
VIc	DNN	0.83	787.57	4.07	2.95	0.81	852.55	4.17	1.47	0.91	581.25	3.44	-2.64	
V 15	MLP	0.69	1 014.68	-22.51	64.19	0.67	1 052.87	-28.60	117.18	0.63	1 100.67	-30.24	86.50	
	RF	0.81	801.64	-12.18	48.36	0.72	954.93	-24.23	136.16	0.68	1 041.26	-29.06	152.94	
	SVM	0.72	981.62	-20.44	64.85	0.59	1 195.88	-39.87	303.09	0.73	953.93	-20.60	79.01	
	LSTM	0.68	1 133.58	25.79	13.47	0.75	997.96	22.17	11.18	0.66	1 165.84	9.21	27.82	
	GBM	0.73	966.06	-20.93	77.22	0.71	982.91	-25.57	146.09	0.65	1 087.12	-23.18	44.28	
TEc	DNN	0.75	969.33	6.01	0.78	0.83	802.86	5.66	-0.13	0.94	479.59	2.09	-1.93	
115	MLP	0.65	1 099.73	-18.81	26.62	0.70	1 019.64	-17.41	33.27	0.54	1 243.69	-36.64	72.93	
	RF	0.79	850.60	-15.27	66.45	0.72	964.68	-21.81	80.83	0.64	1 100.94	-31.89	146.80	
	SVM	0.77	884.47	-16.65	67.78	0.74	941.81	-11.48	20.05	0.63	1 131.60	-34.81	237.04	
	LSTM	0.72	1 063.18	21.76	13.82	0.76	983.48	18.72	13.25	0.71	1 068.20	0.66	38.79	
	GBM	0.71	984.66	-25.84	154.33	0.71	976.52	-27.79	387.35	0.66	1 069.29	-30.10	131.96	
VIc⊥TFc	DNN	0.76	941.87	7.20	2.40	0.80	865.74	4.00	1.32	0.92	556.84	2.03	-1.51	
v15+11-5	MLP	0.72	959.82	-18.11	48.25	0.65	1 076.87	-25.66	54.40	0.58	1 195.89	-32.41	73.82	
	RF	0.82	790.61	-13.26	66.50	0.75	907.17	-21.73	141.52	0.67	1 055.90	-29.38	145.77	
	SVM	0.72	975.52	-21.46	81.49	0.57	1 216.46	-41.69	373.52	0.55	1 254.63	-44.42	569.00	

2.3.2 基于"敏感特征-产量-NUE"模型的 NUE 间接预测 基于 2.2 节产量最佳模型的预测结果,利用式(1) 和式(2)间接预测 aNUE 和 NPFP,结果见图 5。间接 预测 aNUE 与实测 aNUE 的线性拟合 *R*²=0.874, RMSE=
1.421 kg/kg;间接预测 NPFP 与实测 NPFP 的线性拟合 *R*²=0.989, RMSE=0.904 kg/kg。与直接预测对比,间接 预测 NUE 的精度大幅提升:对于 aNUE, *R*²提高了
18.589%, RMSE 降低了 54.411%;对于 NPFP, *R*²提高 了 14.733%, RMSE 降低了 90.015%。

2.4 产量与 NUE 预测结果空间制图

图 6、图 7 为基于最佳 DNN 模型的水稻产量和 NUE 间接预测结果的空间分布。随着施氮量的增加,产 量呈现先增加后降低的趋势,过量施氮对产量有抑制作 用。NUE 随施氮量增加迅速下降。在高氮处理下,水稻 仅吸收利用少量氮肥,大量的氮肥被浪费。尽管田间管 理相同,但因试验设计、气象条件、品种差异和土壤肥 力等因素导致 2 个年份间水稻产量和 NUE 存在显著的 差异。





3 讨论

3.1 敏感特征对模型性能的影响

选择敏感特征对构建高效稳定的 ML 模型至关重 要^[10,25,31]。本文利用 RFE 筛选对产量和 NUE 敏感的特征 (表 2),筛选出的特征在各生育期差异明显,尤其是 对产量敏感的特征。这是因为水稻植株的生长状态、叶 茎(穗)色彩、覆盖度、叶面积以及与水土背景间的几 何关系在不同生育期间存在差异^[32]。如在抽穗期,水稻 植株生长旺盛,冠层密集,覆盖度较高,叶茎(穗)颜 色一致,光谱受背景、饱和效应与枯黄化的叶茎(穗) 的影响较小,所有对绿色植被敏感的 VIs 都可以用于预 测产量^[10,33]。TFs 表达的是冠层图像的局部空间信息, 描述特定窗口内相邻像素间属性值的变化频率,植株各 器官的结构组合、颜色差异、几何排列、背景差异等都 会导致纹理特征的差异^[10]。在灌浆期冠层图像的空间属 性差异最大,因此该时期的敏感 TFs 较分蘖和抽穗期更 多(表 2)。

表 4 基于直接预测模型的 aNUE 预测结果

Table 4	Results of the a	NUE prediction	based on direct	prediction models
---------	------------------	----------------	-----------------	-------------------

	-	分蘖期 Tillering stage					抽穗期 Heading stage				灌浆期 Filling stage			
特征	模型		测试集	变	化率		测试集	变	化率		测试集	变	化率	
Features	Models		Testing set	Chan	ged / %		Testing set	Chan	gea / %		Testing set	Chan	ged / %	
		R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	ΔRMSE	R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	ΔRMSE	R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	$\Delta RMSE$	
	LSTM	0.42	6.81	37.44	20.45	0.29	7.29	102.49	8.46	0.32	7.19	80.07	11.92	
	GBM	0.37	6.47	-48.61	45.92	0.20	7.37	-57.75	22.62	0.21	7.44	-57.70	26.33	
VIc	DNN	0.58	5.38	1.60	3.79	0.52	5.75	-1.32	5.58	0.48	6.05	10.44	4.84	
V 15	MLP	0.42	6.14	-36.68	29.50	0.21	7.35	-67.02	45.50	0.21	7.28	-70.13	56.71	
	RF	0.44	6.05	-41.88	49.36	0.25	7.18	-66.64	68.70	0.33	6.69	-55.82	63.57	
	SVM	0.37	6.42	-49.79	51.75	0.28	7.06	-67.05	115.87	0.17	7.50	-77.23	73.26	
	LSTM	0.42	6.60	41.79	15.30	0.42	6.92	204.29	1.44	0.38	7.03	61.75	16.25	
	GBM	0.30	6.74	-59.67	63.86	0.37	6.44	-42.51	31.03	0.32	6.70	-48.66	32.78	
TEa	DNN	0.54	5.63	8.40	1.22	0.37	6.60	-7.03	5.34	0.43	6.25	3.61	1.85	
115	MLP	0.36	6.47	-46.88	39.22	0.29	6.94	-32.85	11.09	0.34	6.63	-49.49	38.69	
	RF	0.35	6.57	-61.73	159.13	0.29	6.93	-60.77	67.56	0.20	7.36	-70.61	53.16	
	SVM	0.23	7.12	-67.76	58.49	0.35	6.62	-38.00	21.31	0.22	7.22	-66.75	50.09	
	LSTM	0.53	6.24	1.01	41.19	0.29	7.29	102.49	8.46	0.49	6.48	7.22	36.33	
	GBM	0.32	6.66	-58.91	69.13	0.30	6.77	-62.25	83.06	0.32	6.69	-50.98	37.24	
VIa⊥TEa	DNN	0.71	4.45	7.81	-3.54	0.52	5.73	-2.39	5.63	0.56	5.49	2.06	3.04	
VIS+1FS	MLP	0.40	6.27	-50.65	72.74	0.30	6.79	-61.66	81.39	0.34	6.59	-60.28	108.38	
	RF	0.44	6.09	-43.45	54.38	0.27	7.04	-67.44	96.76	0.37	6.48	-54.19	76.02	
	SVM	0.29	6.85	-66.68	138.68	0.24	7.18	-71.32	128.09	0.14	7.59	-84.52	165.41	

表 5 基于直接预测模型的 NPFP 预测结果

Table 5 Results of the NPFP prediction based on direct prediction models

		分蘖期 Tillering stage					抽穗期 Heading stage				灌浆期 Filling stage			
特征	模型		测试集	变	化率		测试集	变	化率		测试集	变	化率	
Features	Models		Testing set	Chan	ged / %		Testing set	Chan	ged / %		Testing set	Chan	ged / %	
		R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	ΔRMSE	R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	ΔRMSE	R^2	$RMSE / (kg \cdot kg^{-1})$	ΔR^2	ΔRMSE	
	LSTM	0.62	18.78	46.09	12.36	0.45	22.39	47.62	20.27	0.54	19.88	49.26	13.53	
	GBM	0.74	13.51	-22.23	123.50	0.29	23.34	-63.28	90.47	0.40	21.46	-46.11	57.38	
VIc	DNN	0.60	17.19	5.57	2.47	0.38	21.02	-4.06	-1.36	0.58	17.72	17.95	-0.39	
V 15	MLP	0.72	14.18	-12.18	24.95	0.57	17.66	-37.38	121.67	0.57	17.67	-34.42	79.33	
	RF	0.72	13.93	-21.82	85.06	0.42	20.75	-53.62	146.96	0.34	22.09	-57.78	78.21	
	SVM	0.74	13.71	-12.08	28.49	0.44	20.52	-53.58	254.28	0.40	21.04	-51.33	80.35	
	LSTM	0.68	16.60	6.98	33.94	0.52	21.08	67.41	13.01	0.51	21.07	36.58	22.54	
	GBM	0.59	17.24	-37.45	162.20	0.53	18.46	-33.73	51.42	0.40	21.09	-53.10	107.32	
TEa	DNN	0.63	16.74	-4.93	12.71	0.54	18.39	0.45	0.93	0.54	18.68	-4.90	5.81	
115	MLP	0.64	16.10	-31.66	133.61	0.52	18.81	-24.51	23.67	0.40	21.11	-54.97	131.58	
	RF	0.63	16.58	-34.05	171.31	0.49	19.31	-42.43	86.01	0.42	20.75	-52.01	122.30	
	SVM	0.56	17.96	-42.13	266.01	0.54	18.14	-26.86	32.66	0.30	22.94	-67.42	192.09	
	LSTM	0.74	15.07	0.08	46.91	0.66	17.73	10.96	34.62	0.63	17.84	15.03	27.90	
	GBM	0.60	16.99	-37.27	193.75	0.50	19.20	-43.30	101.87	0.45	20.31	-37.76	43.73	
VIs+TFs	DNN	0.78	12.79	1.26	3.72	0.67	15.61	-2.57	8.22	0.64	16.37	13.60	-1.50	
	MLP	0.70	14.77	-26.25	153.40	0.64	16.23	-33.38	179.06	0.48	19.62	-50.28	259.21	
	RF	0.70	14.65	-24.90	114.22	0.51	19.00	-43.60	131.78	0.48	19.67	-42.78	76.63	
	SVM	0.62	16.85	-37.60	558.64	0.40	21.34	-58.45	281.24	0.27	23.53	-72.44	458.67	



此外,本文也确定了一些可适用于多个生长阶段的 敏感特征(表 6)。在各生长阶段对产量敏感的 VIs 涵 盖了多光谱传感器的所有波段,一方面证明了利用 VIs 进行产量预测具有普遍性,另一方面也对构建一个稳定、 高效的估产模型带来了挑战^[34]。在各生长阶段对 aNUE 敏感的 VIs 要多于 NPFP, 这是因为 aNUE 考虑不施肥处 理条件下的基本产量,去除了土壤 N 的影响,与 VIs 间 的关系较 NPFP 复杂^[4]。Mean 表示移动窗口内的平均信 息,具有平滑的效应,能够减少水土背景与复杂冠层的 影响^[32],适用于在各生长阶段预测水稻产量。PC1影像 主要反映植株内部的纹理信息,反映特定窗口内变化平

缓的信息^[10], PC1 图像的 Cor 和 Mean 适用于在各生长 阶段预测 aNUE 和 NPFP。Cor 代表像素灰度的相似性, 用于区分背景和水稻植株,有利于估算水稻生长参数^[10,33]。 混合特征的影响规律则完全不同,说明 VIs 与 TFs 间存 在复杂的交互作用。未来研究中一方面要验证共性特征 的稳定性和普适性,一方面还要开发融合多源特征的深 度学习模型及其稳健性检验。



图 7 2022 年产量和 NUE 预测结果空间制图 Fig.7 Spatial mapping of yield and NUE prediction results in 2022

3.2 NUE 直接预测与间接预测对比

基于敏感特征的直接预测方法是当前精准农业领域 的主要手段^[7,35]。如 LIU 等^[4] 基于无人机多光谱影像提 取的植被指数,利用线性回归、多元线性回归和偏最小 二乘回归方法实现了不同生长阶段 aNUE 和 NPFP 的直

接预测,最佳预测精度分别为 R^2 =0.62,RMSE=7.52 kg/kg 和 R^2 =0.70,RMSE=9.59 kg/kg。YANG 等^[13]利用无人机 多光谱影像的 NDRE 在灌浆期基于简单线性回归实现了 aNUE 的预测, R^2 =0.78,RMSE=4 kg/kg。本文基于 ML 模型直接预测 aNUE 的最佳 R^2 =0.711,RMSE=4.448 kg/kg, 高于文献 [4] 结果,但是略低于文献 [13] 结果。一是因 为本文采取了更先进的基于敏感特征的 DNN 预测模型, 二是本文采取 50 次循环随机采样建模,取平均值进行分 析,而 50 次建模精度的最大值 (R^2 =0.789,RMSE= 3.820 kg/kg)要优于文献 [13]。此外,本文对 NPFP 的直 接预测精度为 R^2 =0.781,RMSE=12.787 kg/kg,高于文 献 [4] 中的模型精度及其他类似研究结果^[11]。

表 6 在多个生长阶段均被选择的敏感特征 Table 6 Sensitive features selected at different growth stages

			0
目标 Objects	植被指数交集 Intersection of VIs	纹理特征交集 Intersection of TFs	VIs+TFs 交集 Intersection of VIs+TFs
产量	DVI、VARI 和 mNDblue	PC1Mean 和 PC2Mean	PC2Mean
aNUE	repRVI、DVI、GSAVI、 NIRv、SAVI、VARIre 和 NDVI	PC1Cor 和 PC1Mean	GNDVI、VARIre、 repRVI 和 PC1Mean
NPFP	repRVI	PC1Cor 和 PC1Mean	repRVI 和 mNDblue
NUE	repRVI	PC1Cor 和 PC1Mean	repRVI

NUE 的间接预测以产量为中间变量,通过数学计算 得到,具有明确的计算路径,过程透明,且实现简单, 不需要 ML 模型所需要的驱动数据和算力资源^[5]。与直 接预测对比,间接预测 NUE 的精度大幅提升,是因为 ML 模型对产量的高精准预测和数理方程的零误差累加。 间接预测的另一个优点是预测过程中误差来源确定,误 差分布模式与产量预测模型相似。间接模型中 aNUE 和 NPFP 预测结果的"高低估"现象明显改善(图 5),这 得益于产量预测模型的稳定表现(图 4a),且因 aNUE 计算过程中要考虑不施肥处理下的产量误差,故"高低 估"现象较明显。未来研究应从两个方面进一步提高间 接预测模型的精度,一是提高产量的预测精度,从根本 上带动 aNUE 和 NPFP的精度提升;二是分析 aNUE 的 误差分布,设计针对性的误差消除算法,从而降低计算 误差。

3.3 机器学习算法、特征类型与生长阶段对预测结果的 影响

ML 算法能够有效捕捉遥感特征和作物参数之间的 非线性关系,其预测能力普遍优于单变量或多变量的线 性回归方法^[36]。本文采用的 6 种 ML 模型中,DNN 算法 包含的超参数最多,需要综合考虑隐藏层数量、激活函 数、学习率、优化器等因素。此外,为降低 DNN 模型 的过拟合,本文在隐藏层中引入 L1 正则化惩罚,并通过 提前终止策略优化训练过程,有效提高了模型泛化能力^[37]。 因此,DNN 算法在预测产量和 NUE 时具有最均衡的训 练集和测试集表现以及最佳预测精度。MLP 和 LSTM 同 属神经网络架构,但在本文中的预测表现明显低于 DNN。 MLP 作为最基础的神经网络结构,仅包含一个隐藏层, 神经元数量有限,因而在捕捉遥感特征与作物参数之间 的复杂关系方面存在局限性^[26]。LSTM 虽然具有较强的 时间序列建模能力,但由于小样本数据难以提供充分的 时间依赖性信息,其训练效果受限,易导致欠拟合^[30]。 随着未来遥感监测时序数据的积累,LSTM 在作物参数 预测中的应用潜力仍值得进一步探索。

本文还对比了基于单一类型特征与混合特征的 ML 模型的性能差异。结果表明基于混合特征的估产精度并 不总是优于单一类型特征(表 3),尽管该结论与早期 研究结论不一致,但却在近期的多项研究中被证实^[10,38], 这是由光谱和纹理之间的同质性与冗余性导致的。ML 模型性能受自变量与因变量的响应关系、变量间互相关 以及算法运行机理的综合影响^[36],未来研究中应以产量 和 NUE 预测模型的可解释性为焦点,分析主要变量间的 互作对模型的影响,解构基于混合变量建模时特征数量 增加与混合互补效应对模型的影响。

生长阶段显著影响产量和 NUE 预测模型的准确性。 灌浆期是预测产量的最佳时期,此时期是作物籽粒充实 的关键阶段,光合产物大量向籽粒输送并积累,籽粒质 量迅速增加,直接决定最终产量^[34,39]。分蘖期时 NUE 的 预测精度最优,因为分蘖期水稻生长迅速,生理生化过 程(如细胞增加、根系扩张、光合作用和遗传物质合成 等)强度高,是氮素吸收同化剧烈的生长阶段,且该阶 段叶绿素和氮素之间的相关性有助于通过遥感特征精确 预测 NUE^[4,32]。进入生殖阶段后,储存在茎叶中的氮逐 步转向籽粒,植物体内的氮含量降低,导致叶绿素和氮 含量之间的相关性降低,使得利用遥感特征预测 NUE 的 准确性下降^[8]。此外,生殖阶段由于花序、稻穗的出现 与植株逐渐枯黄使得冠层结构复杂化,进一步降低了遥 感特征对 NUE 预测的准确性^[10]。

4 结 论

在水稻成熟前,准确无损地预测水稻产量和氮素利 用率(nitrogen use efficiency, NUE)对保障稻米高产优 质、优化田间氮肥管理和推动农业绿色发展具有积极的 价值。本文基于无人机遥感技术,提出一种"敏感特征-产量-NUE"的 NUE 间接预测模型,主要研究结果如下:

1) 递归特征消除(recursive feature elimination, RFE)算法可有效筛选对产量和 NU 敏感的遥感特征。 对于产量,在多个生长阶段的敏感特征为 DVI (difference vegetation index)、 VARI (visible atmospherically resistant indices)、 mNDblue (modified normalized difference blue index)和纹理均值(Mean);对于 NUE, 对应的敏感特征为 repRVI (reciprocal ratio vegetation index)、相关性 (correlation, Cor)和 Mean。

2) 深度神经网络(deep neural network, DNN)模型 对产量和 NUE 的预测性能最佳。在灌浆期,基于纹 理特征的产量预测精度最高,决定系数 R^2 =0.938,均方 根误差 RMSE=479.591 kg/hm²;在分蘖期,基于混合特 征的 DNN 模型对农学氮素利用率(agronomic nitrogen use efficiency, aNUE)和氮素偏生产力(nitrogen partial factor productivity, NPFP) 预测性能最佳, 模型精度分 别为 R^2 =0.711, RMSE=4.448 kg/kg 和 R^2 =0.781, RMSE= 12.787 kg/kg。

3) 与直接预测模型相比,间接模型对 NUE 的预测 精度明显提升。对于 aNUE, *R*² 提高了 18.589%, RMSE 降低了 54.411%; 对于 NPFP, *R*² 提高了 14.733%, RMSE 降低了 90.015%。

本文提出的间接预测模型还需在不同地区和多种作 物类型中进一步优化和验证,特别是在过量施肥普遍存 在的地区。此外,未来工作还需进一步评估 NUE 预测模 型的稳定性,并进行优化改进以确保其在不同环境和尺 度下的适用性。

[参考文献]

- 王帝,孙榕,苏勇,等.基于无人机多光谱影像的水稻生物量估测[J].农业工程学报,2024,40(17):161-170.
 WANG Di, SUN Rong, SU Yong, et al. Rice biomass estimation based on multispectral imagery from unmanned aerial vehicles[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(17):161-170. (in Chinese with English abstract)
- [2] 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 Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(12): 174-182. (in Chinese with English abstract)

[3] 钟楚,曹小闯,朱练峰,等.稻田干湿交替对水稻氮素利 用率的影响与调控研究进展[J].农业工程学报,2016, 32(19): 139-147.

ZHONG Chu, CAO Xiaochuang, ZHU Lianfeng, et al. A review on effects and regulation of paddy alternate wetting and drying on rice nitrogen use efficiency[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2016, 32(19): 139-147. (in Chinese with English abstract)

- [4] LIU J, ZHU Y, TAO X, et al. Rapid prediction of winter wheat yield and nitrogen use efficiency using consumer-grade unmanned aerial vehicles multispectral imagery[J]. Frontiers in Plant Science, 2022, 13: 1032170.
- [5] 彭少兵,黄见良,钟旭华,等.提高中国稻田氮肥利用率的研究策略[J].中国农业科学,2002,35(9):1095-1103.
 PENG Shaobing, HUANG Jianliang, ZHONG Xuhua, et al. Research strategy in improving fertilizer-nitrogen use efficiency of irrigated rice in China[J]. Scientia Agricultura Sinica, 2002, 35(9): 1095-1103. (in Chinese with English abstract)
- [6] 曹兵,丁紫娟,侯俊,等. 控释掺混肥结合增密对水稻氮肥利用效率和氨挥发的影响[J].农业工程学报,2022,38(13):56-63.
 CAO Bing, DING Zijuan, HOU Jun, et al. Effects of the blends

of controlled-release and conventional nitrogen fertilizers combined with dense planting on nitrogen use efficiency and ammonia volatilization in a paddy field[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(13): 56-63. (in Chinese with English abstract)

[7] 臧少龙,刘淋茹,高越之,等.基于无人机影像多时相的 小麦品种氮效率分类识别[J].中国农业科学,2024,57(9): 1687-1708.
ZANG Shaolong, LIU Linru, GAO Yuezhi, et al. Classification and identification of nitrogen efficiency of wheat varieties based on UAV multi-temporal images[J]. Scientia Agricultura

Sinica, 2024, 57(9): 1687-1708. (in Chinese with English abstract)
[8] SU X, NIAN Y, YUE H, et al. Improving wheat leaf nitrogen concentration (LNC) estimation across multiple growth stages using fasture combination indices (FCIa) from UAN

- using feature combination indices (FCIs) from UAV multispectral imagery[J]. Agronomy, 2024, 14(5): 1052. [9] 刘建刚,赵春江,杨贵军,等.无人机遥感解析田间作物
- [9] 风莲阁,赵春江,杨贞丰,等. 九八机运恣麻析田尚作初 表型信息研究进展[J]. 农业工程学报, 2016, 32(24): 98-106.

LIU Jiangang, ZHAO Chunjiang, YANG Guijun, et al. Review of field-based phenotyping by unmanned aerial vehicle remote sensing platform[J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(24): 98-106. (in Chinese with English abstract)

- [10] LIU J, ZHU Y, SONG L, et al. Optimizing window size and directional parameters of GLCM texture features for estimating rice AGB based on UAVs multispectral imagery[J]. Frontiers in Plant Science, 2023, 14: 1284235.
- [11] ZHANG J, HU Y, LI F, et al. Meta-analysis assessing potential of drone remote sensing in estimating plant traits related to nitrogen use efficiency[J]. Remote Sensing, 2024, 16(5): 838.
- [12] KEFAUVER S C, VICENTE R, VERGARA-DIAZ O, et al. Comparative UAV and field phenotyping to assess yield and nitrogen use efficiency in hybrid and conventional barley[J]. Frontiers in Plant Science, 2017, 8: 01733.
- [13] YANG M, HASSAN M A, XU K, et al. Assessment of water and nitrogen use efficiencies through UAV-based multispectral phenotyping in winter wheat[J]. Frontiers in Plant Science, 2020, 11: 00927.
- [14] ZHANG H, HE L, CHEN Q, et al. Multi-angular spectroscopic detection of winter wheat nitrogen fertilizer utilization status using integrated feature selection and machine learning[J]. Computers and Electronics in Agriculture, 2025, 231: 109916.
- [15] LIANG T, DUAN B, LUO X, et al. Identification of high nitrogen use efficiency phenotype in rice (Oryza sativa L.) through entire growth duration by unmanned aerial vehicle multispectral imagery[J]. Frontiers in Plant Science, 2021, 12: 740414.
- [16] YIN L, YAN S, LI M, et al. Enhancing soil moisture estimation in alfalfa root-zone using UAV-based multimodal remote sensing and deep learning[J]. European Journal of Agronomy, 2024, 161: 127366.
- [17] CHLINGARYAN A, SUKKARIEH S, WHELAN B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review[J]. Computers and electronics in agriculture, 2018, 151: 61-69.
- [18] MAIMAITIJIANG M, SAGAN V, SIDIKE P, et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. Remote Sensing of Environment, 2020, 237:

第8期

111599.

- [19] DI GENNARO S F, TOSCANO P, GATTI M, et al. Spectral comparison of UAV-based hyper and multispectral cameras for precision viticulture[J]. Remote Sensing, 2022, 14(3): 449.
- [20] 王宇唯,马旭,谭穗妍,等.无人机遥感与地面观测的多 模态数据融合反演水稻氮含量[J].农业工程学报,2024, 40(18): 100-109.

WANG Yuwei, MA Xu, TAN Suiyan, et al. Inverting rice nitrogen content with multimodal data fusion of unmanned aerial vehicle remote sensing and ground observations[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(18): 100-109. (in Chinese with English abstract)

[21] 宋耀邦,宣传忠,唐朝辉,等.基于无人机高光谱和机器
 学习的荒漠草原地上生物量估算[J].农业工程学报,2025,41(4):135-143.

SONG Yaobang, XUAN Chuanzhong, TANG Zhaohui, et al. Estimating aboveground biomass in desert steppe using UAV hyperspectral and machine learning[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(4): 135-143. (in Chinese with English abstract)

- [22] Liu J, Wang W, Li J, et al. UAV remote sensing technology for wheat growth monitoring in precision agriculture: Comparison of data quality and growth parameter inversion[J]. Agronomy 2025, 15(1): 159.
- [23] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms forremote estimation of vegetation fraction[J]. Remote Sensing of Environment. 2002, 80(1): 76–87.
- [24] BADGLEY G, FIELD C B, BERRY J A. Canopy near-infrared reflectance and terrestrial photosynthesis[J]. Science advances. 2017, 3 (3): 1602244.
- [25] SU X, NIAN Y, SHAGHALEH H, et al. Combining features selection strategy and features fusion strategy for SPAD estimation of winter wheat based on UAV multispectral imagery[J]. Frontiers in Plant Science, 2024, 15: 1404238.
- [26] 李清彩,陈娟,赵庆令,等.基于深度学习的小麦籽粒锌 含量预测及安全利用分区[J].农业环境科学学报,2024, 43(10): 2248-2259.
 LING Qingcai, CHEN Juan, ZHAO Qingling, et al. Prediction and safe utilization zoning of zinc content of wheat kernels based on deep learning[J]. Journal of Agro-Environment Science, 2024, 43(10): 2248-2259. (in Chinese with English abstract)
- [27] HAMZEHPOUR N, SHAFIZADEH-MOGHADAM H, VALAVI R. Exploring the driving forces and digital mapping of soil organic carbon using remote sensing and soil texture[J]. Catena, 2019, 182: 104141.
- [28] MA Y, LIANG S, MYERS D B, et al. Subfield-level crop yield mapping without ground truth data: A scale transfer framework[J]. Remote Sensing of Environment, 2024, 315: 114427.
- [29] TIAN S, SHA A, LUO Y, et al. A novel framework for river organic carbon retrieval through satellite data and machine learning[J]. ISPRS Journal of Photogrammetry and Remote

Sensing, 2025, 221: 109-123.

- [30] TIAN H, WANG P, TANSEY K, et al. An LSTM neural network for improving wheat yield estimates by integrating remote sensing data and meteorological data in the Guanzhong Plain, PR China[J]. Agricultural and Forest Meteorology, 2021, 310: 108629.
- [31] 运彬媛,谢铁娜,李虹,等.融合无人机光谱与纹理信息的玉米氮素营养估测[J].中国农业科学,2024,57(16):3154-3170.
 YUN Binyuan, XIE Tiena, LI Hong, et al. Nitrogen nutrition estimation of maize based on UAV spectrum and texture information[J]. Scientia Agricultura Sinica, 2024, 57(16):3154-3170. (in Chinese with English abstract)
- [32] XU T, WANG F, SHI Z, et al. Dynamic estimation of rice aboveground biomass based on spectral and spatial information extracted from hyperspectral remote sensing images at different combinations of growth stages[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 202: 169-183.
- [33] XU T, WANG F, SHI Z, et al. Multi-scale monitoring of rice aboveground biomass by combining spectral and textural information from UAV hyperspectral images[J]. International Journal of Applied Earth Observation and Geoinformation, 2024, 127: 103655.
- [34] VAN K T, KASSAHUN A, CATAL C. Crop yield prediction using machine learning: A systematic literature review[J]. Computers and Electronics in Agriculture, 2020, 177: 105709.
- [35] 高晨凯,刘水苗,李煜铭,等.冬小麦水分利用效率相关 驱动因子及其预测模型构建[J].中国农业科学,2024, 57(7): 1281-1294.
 GAO Chenkai, LIU Shuimiao, LI Yuming, et al. The related driving factors of water use efficiency and its prediction model construction in winter wheat[J]. Scientia Agricultura Sinica, 2024, 57(7): 1281-1294. (in Chinese with English abstract)
- [36] 汪静平,吴小丹,马杜娟,等.基于机器学习的遥感反演: 不确定性因素分析[J]. 遥感学报, 2023, 27(3): 790-801.
 WANG Jingping, WU Xiaodan, MA Dujuan, et al. Remote sensing retrieval based on machine learning Algorithm: Uncertainty analysis[J]. National Remote Sensing Bulletin, 2023, 27(3): 790-801. (in Chinese with English abstract)
- [37] MURO J, LINSTADTER A, MAGDON P, et al. Predicting plant biomass and species richness in temperate grasslands across regions, time, and land management with remote sensing and deep learning[J]. Remote Sensing of Environment, 2022, 282: 113262.
- [38] LI X, SU X, LI J, et al. Coupling image-fusion techniques with machine learning to enhance dynamic monitoring of nitrogen content in winter wheat from UAV multi-source[J]. Agriculture, 2024, 14(10): 1797.
- [39] 王鹏新,王颖,田惠仁,等.基于 LightGBM 的冬小麦产量 估测与可解释性研究[J].农业机械学报,2023,54(12): 197-206.
 WANG Pengxin, WANG Ying, TIAN Huiren, et al. Interpretability on yield estimation of winter wheat based on LightGBM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 197-206. (in Chinese with English abstract)

Prediction of rice yield and nitrogen use efficiency based on UAV multispectral imaging and machine learning

LIU Jikai^{1,2}, WANG weiqiang¹, SU Xiangxiang¹, LI Jun¹, NIAN Ying¹, ZHU Xueqing¹, MA Qiang¹, LI Xinwei^{1,2,3 \times}

 College of Resource and Environment, Anhui Science and Technology University, Fengyang 233100, China;
 Anhui Province Crop Intelligent Planting and Processing Technology Engineering Research Center, Fengyang 233100, China;
 Anhui Province Key Laboratory of Functional Agriculture and Functional Food, Chuzhou 239000, China)

Abstract: Rice is one of the most important staple crops worldwide, with China being the largest rice producer. Rice yield and nitrogen use efficiency (NUE) are critical factors determining food security and agricultural sustainability. Nitrogen (N) is an essential nutrient for rice growth; however, excessive nitrogen fertilizer application reduces NUE, increases production costs, and causes environmental pollution. Therefore, accurately predicting rice yield and NUE is crucial for optimizing nitrogen management, improving rice production efficiency, and mitigating environmental impacts. In recent years, the development of remote sensing technology, particularly the application of unmanned aerial vehicle (UAV) multispectral imagery, has significantly enhanced the precision management of agricultural production. UAV remote sensing technology enables efficient acquisition of crop growth status information and, when combined with machine learning approaches, facilitates the construction of accurate predictive models, thereby providing data support and decision-making assistance for agricultural production.A two-year field experiment was conducted in Fengyang County, Anhui Province, China, involving multiple nitrogen levels and rice varieties. UAV multispectral images were collected at three key growth stages (tillering, heading, and grain filling stages) to obtain remote sensing data. The recursive feature elimination (RFE) algorithm was used to select sensitive vegetation indices (VIs), texture features (TFs), and their combined features. Six machine learning models-random forest (RF), support vector machine (SVM), multilayer perceptron (MLP), gradient boosting machine (GBM), deep neural network (DNN), and long short-term memory (LSTM)-were employed to establish direct prediction models based on "sensitive remote sensing features-yield and NUE" Additionally, an indirect prediction model based on "sensitive remote sensing features-yield-NUE" was proposed using calculated features. The potential of UAV remote sensing technology for accurate NUE prediction was evaluated by comparing the performance of direct and indirect models. The results showed that: (1) The prediction of rice yield and NUE at different growth stages exhibited varying dependencies on remote sensing features. At the tillering stage, spectral-based vegetation indices contributed more to prediction accuracy, whereas at the grain filling stage, texture features played a more significant role in NUE prediction. Difference vegetation index (DVI), visible atmospherically resistant indices (VARI), and modified normalized difference blue index (mNDblue), as well as the texture mean (Mean), were sensitive to yield across multiple growth stages. Similarly, reciprocal ratio vegetation index (repRVI), correlation (Cor), and Mean were consistently sensitive to NUE. (2) Among all models, the deep neural network (DNN) achieved the highest accuracy in direct predictions of yield and NUE. At the grain filling stage, the TF-based model provided the most accurate yield predictions ($R^2 = 0.938$, RMSE = 479.591 kg/hm²). At the tillering stage, the hybrid feature-based model demonstrated the best predictive performance for NUE, with agronomic nitrogen use efficiency (aNUE) and nitrogen partial factor productivity (NPFP) achieving R^2 values of 0.711 (RMSE = 4.448 kg/kg) and 0.781 (RMSE = 12.787 kg/kg), respectively. (3) Compared to direct models, the indirect model significantly improved NUE prediction accuracy. The R^2 values for aNUE and NPFP increased by 18.589% and 14.733%, while RMSE values decreased by 54.411% and 90.015%, respectively. The proposed indirect prediction framework for NUE overcomes the limitations of traditional methods that rely on data from the maturity stage, enabling nondestructive and dynamic assessment at earlier growth stages. This study demonstrates that UAV multispectral imagery combined with machine learning techniques effectively enhances the prediction accuracy of rice yield and NUE. The DNN model outperforms traditional machine learning models in predictive accuracy, and the indirect prediction method surpasses the direct approach. These findings provide a novel methodology for precision management in rice production and offer valuable technical support for intelligent agricultural management.

Keywords: unmanned aerial vehicle(UAV); multispectral image; yield; nitrogen use efficiency(NUE); indirect prediction model; machine learning(ML)