

doi:10.6041/j.issn.1000-1298.2026.11.027

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

樊杰杰^{1,2} 樊意广^{1,2} 马彦鹏^{1,3} 边明博^{1,3} 冯海宽^{1,3}

(1.北京市农林科学院信息技术研究中心,北京 100097; 2.西北农林科技大学信息工程学院,陕西杨凌 712100;
3.农业农村部农业遥感机理与定量遥感重点实验室,北京 100097)

摘要: 实时监测氮素养分状态对于提高肥料效率和作物产量、品质至关重要。作物氮素监测在精准农业中具有重要意义,但传统的土壤和叶片采样方法难以满足大范围、实时监测的需求。本研究结合 RGB 与多光谱传感器的多源数据,构建了冬小麦叶片氮含量(Leaf nitrogen content, LNC)估算模型,旨在提升氮素监测精度。首先基于无人机 RGB 与多光谱影像提取冬小麦的多源特征信息,并通过结合 Pearson 相关性分析与变量投影重要性(Variable importance in projection, VIP)的“两段式”特征筛选策略识别关键变量,融合颜色空间、纹理和光谱特征参数进行 LNC 估算。结果表明,融合模型在不同生育期的估算精度显著优于单一传感器模型, R^2 提高了 0.03 ~ 0.16, RMSE 降低了 0.02 ~ 0.10 个百分点, NRMSE 减少了 0.61 ~ 3.90 个百分点,其中 SVR 模型表现最佳。研究表明,多源遥感信息融合能够有效提升 LNC 估算精度,突破了单一传感器的局限,为精准农业提供了新的技术方法和理论支持。

关键词: 冬小麦; 叶片氮含量; 无人机遥感; 多源遥感信息融合

中图分类号: S25

文献标识码: A

文章编号: 1000-1298(2026)11-0314-11

OSID:



Monitoring Method for Winter Wheat Leaf Nitrogen Content Based on UAV Multi-source Remote Sensing Fusion

FAN Jiejie^{1,2} FAN Yiguang^{1,2} MA Yanpeng^{1,3} BIAN Mingbo^{1,3} FENG Haikuan^{1,3}

(1. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China
2. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

3. Key Laboratory of Quantitative Remote Sensing in Agriculture, Ministry of Agriculture and Rural Affairs, Beijing 100097, China)

Abstract: Real-time monitoring of nitrogen status is essential for improving fertilizer use efficiency and crop yield and quality. Nitrogen monitoring plays a key role in precision agriculture; however, traditional soil and leaf sampling methods cannot meet the requirements for large-scale, real-time monitoring. Multi-source data from RGB and multi-spectral sensors were integrated to develop a model for estimating leaf nitrogen content (LNC) in winter wheat, with the aim of improving the accuracy and reliability of nitrogen monitoring. Multi-source features were first extracted from UAV-based RGB and multi-spectral imagery acquired at key growth stages. Key variables were then identified by using a two-stage feature selection strategy that combined Pearson correlation analysis and variable importance in projection (VIP). Color space, texture, and spectral features were subsequently integrated to construct LNC estimation models. The results showed that the fused models consistently outperformed single-sensor models across different growth stages. Among the tested methods, the support vector regression (SVR) model achieved the best performance, with R^2 increased by 0.03 ~ 0.16, RMSE decreased by 0.02 ~ 0.10 percentage points, and NRMSE reduced by 0.61 ~ 3.90 percentage points. These findings demonstrated that multi-source remote sensing data fusion can effectively improve LNC estimation accuracy and model robustness. The research result showed that multi-source remote sensing information fusion can effectively improve the accuracy of LNC estimation, overcome the limitations of a single sensor, and provide technical approaches and theoretical support for precision agriculture.

Key words: winter wheat; leaf nitrogen content; UAV remote sensing; multi-source remote sensing information fusion

收稿日期: 2025-12-25 修回日期: 2026-01-16

基金项目: 国家重点研发计划项目(2023YFD2000102)和北京市农林科学院 2025 年度科研创新平台建设项目(PT2025-26)

作者简介: 樊杰杰(1997—),男,博士生,主要从事农业定量遥感研究,E-mail: fanjj74@163.com

通信作者: 冯海宽(1982—),男,副研究员,博士生导师,主要从事农业定量遥感研究,E-mail: fenghaikuan123@163.com

0 引言

氮是冬小麦生长和发育的必需营养素,是蛋白质、核酸及其他关键有机化合物的基本成分^[1]。氮的过量和不足都可能对冬小麦生长和整体产量品质产生负面影响^[2]。为降低这些风险,实时、非侵入性的氮监测对于提高冬小麦生产效率、同时最大限度减少环境影响至关重要^[3]。

传统的氮监测依赖破坏性采样和实验室分析,这些方法常常在空间和时间覆盖方面存在限制^[4]。随着无人机遥感技术的发展,基于遥感图像的氮含量反演模型为无损且快速的监测提供了有效替代方案,并被广泛应用于估算叶片氮含量(Leaf nitrogen content, LNC),支持农业养分管理的改进^[5]。无人机平台作为一种近地面遥感手段,兼具灵活性与高分辨率优势,能够有效弥补卫星遥感在时间和空间分辨率方面的不足。与传统近地面冠层高光谱遥感方式相比,无人机遥感具备覆盖范围更大、机动性更强等特点,在农业监测等应用中表现出更高的实用价值。因此,利用无人机遥感影像探索冬小麦 LNC 反演模型,在提升冬小麦种植管理和实现精准农业方面具有重要实际意义。由于高光谱传感器成本较高,多数无人机平台主要搭载 RGB 或多光谱相机开展作物氮素监测,相关研究多集中于单一传感器的估算能力评估。已有研究表明,基于无人机 RGB 影像,结合植被指数构建、统计筛选方法及偏最小二乘回归模型,可实现冬小麦不同生育期氮素含量的有效估算^[6-7];多光谱影像则通过红边和近红外波段,在叶氮浓度和植株氮浓度监测方面表现出较高精度^[8]。总体来看,RGB 影像具有空间分辨率高的优势,但可见光信息对氮素动态响应能力有限,而多光谱影像在作物氮素监测中更具优势。进一步研究发现,传统仅依赖光谱信息的氮含量估算模型易受土壤背景和冠层结构复杂性影响,限制了估算精度^[9]。近年来,多源数据融合方法逐渐兴起,通过整合多维遥感特征,有效弥补单一光谱信息的不足,提高模型的鲁棒性和精度。相关研究表明,融合 RGB 与多光谱植被指数、纹理特征及其他空间特征,并结合随机森林、支持向量回归等机器学习算法,可显著提升冬小麦不同生育期氮素含量或 LNC 的估算精度^[10-11]。总体而言,无人机遥感结合多源特征融合与机器学习方法,在作物氮素监测中展现出良好的应用潜力和发展前景。

现有研究多侧重于单一传感器下的单类或多类特征对氮含量的表征^[12],难以充分发挥遥感信息的互补优势。RGB 传感器具备较高空间分辨率,所获

取影像可提供丰富的空间信息;多光谱传感器则覆盖红边与近红外等氮素敏感波段,更适于反映作物氮素状态。基于此,本研究融合两类传感器的多源遥感信息构建冬小麦 LNC 估算模型,旨在发挥不同传感器优势,以提升无人机尺度下氮素估算的精度与稳健性,拓展其在区域农业营养监测中的应用潜力。

1 材料与方法

1.1 试验设计

研究区位于北京市昌平区小汤山镇国家精准农业研究示范基地(40°10'34"N,116°26'39"E)。试验田共划分为 64 个小麦试验小区,设置 n 区和 s 区两个区域,每个区域东西向长度为 80 m、南北向长度为 60 m,单个小区面积为 15 m × 9 m。试验选用中麦 1062 (P1) 和京花 11 (P2) 2 个冬小麦品种,于 2023 年 9 月 28 日播种并施入基肥,2024 年 4 月 12 日进行追肥处理,基肥与追肥阶段均设定 4 个相同的氮素施用水平,分别为 0 g/m² (N0)、4.485 g/m² (N1)、8.97 g/m² (N2,常规处理) 和 13.46 g/m² (N3)。其中,n 区设置 3 次重复(含一次对照),s 区设置 4 次重复,两区共形成 9 种相同的处理组合,具体布局如图 1 所示。整个试验期间,冬小麦的田间管理依据当地常规生产方式开展,主要包括除草和灌溉等措施。




图 1 研究区示意图

Fig. 1 Schematic of study area

1.2 数据获取与处理

1.2.1 无人机影像的获取及预处理

采用大疆创新科技有限公司(深圳)研发的精灵 4 系列无人机获取遥感影像,平台搭载 RGB 相机

和多光谱传感器。RGB 成像系统采用 2 000 万像素、1 英寸 CMOS 传感器,等效焦距为 28 mm,光圈范围为 $f/2.8 \sim f/11$;多光谱传感器由 6 个 $1/2.9$ 英寸 CMOS 传感器组成,包括 1 个全色波段和 5 个多光谱波段,各波段分辨率为 200 万像素。

影像采集前,利用 DJI GS Pro 软件进行航线规划,飞行过程中相机保持垂直于地面并采用自动曝光模式。作业时间安排在 10:00—14:00,气象条件稳定。为保证影像拼接质量,航向和旁向重叠率均设为 80%。RGB 和多光谱无人机的飞行高度分别为 20 m 和 30 m。多光谱数据采集前,拍摄标准反射率参考板用于辐射定标。飞行结束后,使用 DJI Terra 软件完成辐射校正和正射影像拼接,并在各小区内计算感兴趣区域像元的平均值,作为无人机波段数据的代表值。

1.2.2 氮含量测定

试验于冬小麦关键生育阶段开展,分别在拔节期(2024 年 4 月 11 日)、挑旗期(2024 年 5 月 4 日)、开花期(2024 年 5 月 15 日)和灌浆期(2024 年 5 月 22 日)进行取样。每个生育期在各小区内选取 30 株具有代表性的植株作为样本,装入密封袋带回实验室后进行茎叶分离,分别称量叶片、茎和穗的鲜质量。随后样品在 105℃ 条件下杀青 0.5 h,再于 80℃ 下烘干至恒质量并称量;干燥样品经研磨粉碎后,采用凯氏定氮法测定氮含量,获得冬小麦叶片 LNC 实测数据。共获取 192 个有效样本,其分布特征通过箱线图和正态曲线进行展示(图 2)。拔节期 LNC 范围为 2.35%~4.56%,均值为 3.66%,标准差为 0.63%;开花期为 2.22%~5.00%,均值为 3.69%,标准差为 0.71%;灌浆期为 1.83%~4.36%,均值为 3.23%,标准差为 0.66%。冬小麦 LNC 随生育进程呈现先升后降的变化趋势,在拔节期和开花期因氮素需求较高而维持在较高水平,并在开花期达到峰值。




图 2 各生育期冬小麦 LNC 统计分布

Fig.2 Statistical distribution of LNC in winter wheat at different growth stages

1.2.3 无人机影像特征提取

1.2.3.1 RGB 颜色空间参数

颜色空间是用于描述和量化颜色信息的数学表达形式,通常借助多维坐标体系对颜色特征进行表征。在常用的 RGB 颜色空间中,作物冠层颜色由红、绿、蓝三原色分量(R、G、B)进行刻画。将 RGB 颜色空间进一步转换为 HSV、 $L^*a^*b^*$ 、 $L^*c^*h^*$ 和 $L^*u^*v^*$ ^[13],可获得反映不同颜色属性和层次信息的多种参数,有助于更全面地表征冬小麦的氮素营养状况。

1.2.3.2 RGB 纹理特征参数

纹理特征主要通过灰度值变化表征地物表面的视觉粗糙程度与空间结构信息,其中灰度共生矩阵(Gray level co-occurrence matrix, GLCM)因计算效率高且能表征多尺度与方向性特征而被广泛应用^[14]。基于 GLCM 计算的纹理参数包括均值(Mean, MEA)、方差(Variance, VAR)、均匀性(Homogeneity, HOM)、对比度(Contrast, CON)、差异性(Dissimilarity, DIS)、熵(Entropy, ENT)、角二矩(Second moment, SEM)以及相关系数(Correlation, COR)。已有研究表明,滑动窗口尺寸及其方向对 GLCM 纹理特征的提取结果影响较小^[15]。本研究借助 ENVI 软件内置的 GLCM 模块,从冬小麦高分辨率 RGB 冠层影像中提取纹理特征,窗口大小设置为 3×3,方向角为 45°,在各生育期共获得 24 个纹理特征参数。

1.2.3.3 多光谱特征参数

植被指数(Vegetation indices, VIs)是表征植被生长状况和作物长势的重要遥感参数^[16],可在一定程度上削弱土壤背景和噪声对光谱信息的影响,提高植被参数反演精度。VIs 通常由不同光谱波段反射率通过线性或非线性组合获得,广泛用于表征植被健康状况和养分水平。本研究选取 11 种常用植被指数作为冬小麦 LNC 反演的光谱特征变量,用于刻画不同生育期的光谱特性变化,分别为 NDVI^[17]、GNDVI^[18]、NDRE^[19]、LCI^[20]、OSAVI^[21]、DVI^[22]、RVI^[22]、EVI^[23]、EVI2^[24]、MCARI^[25]、MSR^[26]。相关研究表明,这些指数在作物氮素监测中具有良好的适用性和稳定性^[27-28]。基于辐射校正后的无人机多光谱影像,提取 Blue、Green、Red、RedEdge 和 NIR 波段反射率,并计算各试验小区像元的平均值,作为后续分析的光谱特征参数。

1.3 特征参数筛选方法

在多源遥感特征建模过程中,单一特征筛选方法难以同时兼顾特征与冬小麦 LNC 之间的统计相关性及其在回归建模中的实际贡献。基于此,本研

究采用“两段式”特征筛选策略：首先通过 Pearson 相关性分析评估各特征与 LNC 之间的统计关联性，初步剔除相关性较弱的变量；随后在此基础上引入变量投影重要性 (Variable importance in projection, VIP) 方法,进一步量化特征在回归建模过程中的相对贡献,筛选在统计相关性和预测能力两方面均具有代表性的关键特征。该策略通过综合相关性分析与模型重要性评估,在一定程度上弥补单一筛选方法的不足,为后续多源遥感特征融合建模提供稳定可靠的特征基础。

1.3.1 Pearson 相关性分析

相关性分析是一种用于评估两个或多个变量之间关联程度的统计方法,旨在揭示变量之间是否存在显著的相关关系及其强弱程度。具体方法包括 Pearson、Spearman、Kendall、Polychoric、Tetrachoric 和 Polyserial 6 种系数^[29]。本研究选择 Pearson 相关性分析来衡量输入特征与目标参量的变化一致性,具体衡量指标为 Pearson 相关系数 r ,该值输出范围为 -1 至 1,绝对值越大,越接近于 1 则表示输入特征与目标参量相关性程度越高。

1.3.2 变量投影重要性

VIP 是一种基于偏最小二乘回归的变量筛选方法,可量化自变量在模型中的相对贡献并进行排序,以识别关键特征。与传统方法相比,VIP 在小样本和变量高度相关的条件下具有更好的稳定性和筛选效果,能够提升模型的稳健性和预测精度^[30]。

VIP 指标用于衡量各自变量在解释因变量过程中的相对作用。 S_{VIP_i} 值越大,表明该变量在模型构建中对因变量的贡献程度越高^[31]。鉴于 S_{VIP_i} 得分平方的平均值为 1,研究中通常采用 $S_{VIP_i} > 1$ 的经验准则进行特征筛选。将 S_{VIP_i} 值大于 1 的变量视为对预测模型具有显著贡献的特征,并据此确定变量筛选阈值。

1.4 模型构建

按照比例 7:3 将数据划分为建模集和验证集。采用的数据分析方法为高斯过程回归 (Gaussian process regression, GPR)、随机森林回归 (Random forest regression, RFR) 和支持向量回归 (Support vector regression, SVR)。GPR 是一种非参数贝叶斯回归模型,能够在不限制核函数形式的情况下逼近任意连续函数,并提供预测值及其不确定性^[32]。RFR 通过在随机数据子集上训练多棵决策树并平均其结果,实现对小样本高维数据的稳健预测^[33],具有较强抗过拟合能力。SVR 将支持向量机扩展至回归问题,通过核函数映射数据至高维空间,从而寻找最优回归超平面以最小化预测误差^[34]。

模型训练采用五折交叉验证结合网格搜索确定

最优参数,即将训练集分为 5 个子集,每次使用 4 个子集建模,剩余子集验证,并通过不同参数组合评估性能,最终利用独立验证集进行预测。模型性能通过决定系数 (R^2)、均方根误差 (RMSE) 和归一化均方根误差 (NRMSE) 评价,其中 R^2 衡量模型对数据变异的解释能力, RMSE 反映预测误差大小, NRMSE 作为相对指标评估预测结果一致性,值越低表示模型预测效果越好。

2 结果与分析

2.1 无人机影像特征变量筛选

对颜色空间参数、纹理特征参数和多光谱特征参数与冬小麦 LNC 进行相关性分析。结果表明 (表 1 和表 2), 3 类特征参数在不同生育期与冬小麦 LNC 的相关性表现存在差异。对于颜色空间参数,拔节期除少数参数外多数与 LNC 呈显著相关,开花期相关性整体增强并达到最高,而灌浆期相关性有所减弱,仅部分参数保持显著相关,体现出随生育进程变化的动态特征;对于纹理特征参数,拔节期和开花期大多数参数与 LNC 显著相关,其中开花期相关性相对较强,而灌浆期相关性明显下降,仅个别参数仍保持显著相关;相比之下,多光谱特征参数在各生育期均与 LNC 呈显著正相关,整体相关性水平较高,其中灌浆期相关性最强,表现出较好的稳定性和一致性。

基于 Pearson 相关性分析结果,初步选取 $p \leq 0.05$ 或 $p \leq 0.01$ 水平下所有相关的变量,进一步采用 VIP 方法对颜色空间、纹理和光谱特征参数进行二次筛选 (图 3)。结果表明,不同生育期筛选出的关键特征数量和类型存在明显差异。颜色空间参数中,拔节期筛选出 B、H、 b^* 、 h^* 、 u^* 和 v^* 共 6 个特征,开花期保留 H、 b^* 、 h^* 和 u^* 4 个特征,灌浆期筛选出 H、S、 b^* 、 h^* 、 u^* 和 v^* 6 个特征。纹理特征方面,拔节期筛选出 B_MEA、B_VAR、B_CON、G_MEA、G_VAR、G_CON、G_COR 和 R_VAR 共 8 个特征,开花期筛选出 B_MEA、B_VAR、B_COR、G_VAR、G_HOM、G_COR、R_VAR、R_ENT、R_SEM 和 R_COR 共 10 个特征,灌浆期仅保留 B_MEA 和 G_MEA。光谱特征参数中,拔节期筛选出 GNDVI、RVI、EVI 和 MCARI,开花期为 NDRE、LCI、EVI 和 MCARI,灌浆期为 NDRE、LCI、RVI 和 EVI,各生育期筛选结果呈现明显的阶段性差异。

2.2 基于无人机单源信息估算冬小麦 LNC

2.2.1 基于 RGB 影像特征估算冬小麦 LNC

基于“两段式”颜色空间特征筛选结果,构建多种机器学习模型对冬小麦 LNC 进行估算 (图 4)。

表 1 颜色空间、光谱特征参数与 LNC 的相关系数

Tab.1 Correlation coefficients between color space, spectral characteristic parameters and LNC

颜色空间参数	拔节期	开花期	灌浆期	光谱特征参数	拔节期	开花期	灌浆期
R	-0.15	-0.23	0.08	NDVI	0.66 **	0.74 **	0.83 **
G	-0.47 **	-0.58 **	-0.32 *	GNDVI	0.67 **	0.80 **	0.87 **
B	-0.62 **	-0.65 **	-0.64 **	NDRE	0.69 **	0.85 **	0.88 **
H	-0.69 **	-0.84 **	-0.81 **	LCI	0.69 **	0.84 **	0.88 **
S	-0.22	-0.28	-0.78 **	OSAVI	0.67 **	0.80 **	0.86 **
V	-0.47 **	-0.58 **	-0.36 **	DVI	0.68 **	0.82 **	0.86 **
L*	-0.45 **	-0.55 **	-0.31 *	RV1	0.65 **	0.79 **	0.88 **
a*	-0.17	0.35 *	0.11	EVI	0.70 **	0.85 **	0.87 **
b*	0.69 **	0.74 **	0.78 **	EVI2	0.68 **	0.81 **	0.82 **
c*	0.46 **	0.29	0.26	MCARI	0.64 **	0.63 **	0.74 **
h*	-0.69 **	-0.78 **	-0.78 **	MSR	0.66 **	0.79 **	0.87 **
u*	0.52 **	0.84 **	0.71 **				
v*	0.68 **	0.69 **	0.75 **				

注:数值上的*表示0.05水平显著性相关,**表示0.01水平显著性相关,下同。

表 2 纹理特征参数与 LNC 的相关系数

Tab.2 Correlation coefficients between texture characteristic parameters and LNC

纹理特征参数	拔节期	开花期	灌浆期	纹理特征参数	拔节期	开花期	灌浆期
B_CON	0.53 **	0.40 **	0.22	G_HOM	-0.41 **	0.20	-0.32 *
B_COR	0.43 **	0.46 **	0.26	G_MEA	-0.47 **	-0.58 **	-0.40 **
B_DIS	0.51 **	0.27	0.28	G_SEM	-0.39 **	0.36 *	0.10
B_ENT	0.36 *	-0.37 *	-0.15	G_VAR	0.58 **	0.55 **	0.25
B_HOM	-0.37 *	0.28	-0.32 *	R_CON	0.53 **	0.42 **	0.21
B_MEA	-0.62 **	-0.65 **	-0.73 **	R_COR	0.42 **	0.48 **	0.25
B_SEM	-0.35 *	0.36 *	0.20	R_DIS	0.50 **	0.30 *	0.27
B_VAR	0.58 **	0.55 **	0.28	R_ENT	0.34 **	-0.32 *	-0.12
G_CON	0.54 **	0.40 **	0.19	R_HOM	-0.35 *	0.21	-0.31 *
G_COR	0.46 **	0.47 **	0.25	R_MEA	-0.15 **	-0.23	0.03
G_DIS	0.52 **	0.30 *	0.26	R_SEM	-0.32 *	0.33 *	0.16
G_ENT	0.40 **	-0.35 *	-0.07	R_VAR	0.57 **	0.57 **	0.28




图 3 变量投影重要性结果

Fig.3 VIP results




图 4 基于不同生育期颜色空间参数估算冬小麦 LNC 估算模型性能对比雷达图

Fig. 4 Radar chart comparing the performance of winter wheat LNC estimation models based on color space parameters at different growth stages

结果显示,拔节期验证 R^2 为 0.63, RMSE 为 0.40% ~ 0.41%, NRMSE 为 18.01% ~ 18.54%; 开花期验证 R^2 为 0.66 ~ 0.68, RMSE 为 0.46%, NRMSE 为 17.61% ~ 17.95%; 灌浆期验证 R^2 提升至 0.74 ~ 0.75, RMSE 为 0.41% ~ 0.42%, NRMSE 为 16.32% ~ 16.62%。总体而言,各生育期模型的 R^2 均超过 0.60,其中灌浆期估算精度最高。在不同建模方法中,GPR 在 3 个生育期均取得最优结果,表现为较高的 R^2 和较低的 RMSE 与 NRMSE;SVR 次之,RFR 精度相对较低。

纹理特征能够有效表征遥感影像中的空间结构




图 5 基于不同生育期纹理特征参数估算冬小麦 LNC 估算模型性能对比雷达图

Fig. 5 Radar chart comparing the performance of winter wheat LNC estimation models based on texture characteristic parameters at different growth stages

为评估低成本 RGB 传感器颜色空间特征与纹理特征在冬小麦 LNC 估算中的综合作用,本研究融合 2 类特征构建 LNC 估算模型(表 3)。结果表明,3 种模型在灌浆期的估算精度最高,其次为开花期,

信息,已广泛应用于作物农学参数反演^[35]。作物氮素水平的变化会引起叶片形态和冠层结构差异,从而导致影像纹理特征发生变化。基于此,本研究采用“两段式”方法筛选纹理特征参数并构建冬小麦 LNC 估算模型(图 5)。结果显示,不同生育期模型精度存在明显差异,其中灌浆期估算效果最佳(R^2 为 0.72 ~ 0.75, RMSE 为 0.41% ~ 0.45%, NRMSE 为 16.01% ~ 17.95%),开花期次之,拔节期相对较低。各建模方法中,GPR 在各生育期均表现最优, R^2 均高于 0.65,最低 NRMSE 为 16.01%,表明基于 GLCM 的纹理特征在冬小麦 LNC 估算中具有较高应用价值。

拔节期相对较低。其中,GPR 在各生育期均表现最优,拔节期、开花期和灌浆期的 R^2 分别为 0.68、0.72 和 0.78, RMSE 分别为 0.38%、0.42% 和 0.39%, NRMSE 分别为 17.26%、16.31% 和 15.55%。

表 3 颜色空间参数结合纹理特征参数估算冬小麦 LNC 结果

Tab.3 Estimation of winter wheat LNC using color space parameters combined with texture characteristic parameters

生育期	学习 方法	机器	建模集			验证集		
			R^2	RMSE/ %	NRMSE/ %	R^2	RMSE/ %	NRMSE/ %
拔节期	GPR	0.73	0.30	14.19	0.68	0.38	17.26	
	RFR	0.82	0.25	11.84	0.65	0.39	17.51	
	SVR	0.81	0.27	12.65	0.67	0.39	17.46	
开花期	GPR	0.74	0.33	13.80	0.72	0.42	16.31	
	RFR	0.90	0.20	8.28	0.72	0.43	16.42	
	SVR	0.81	0.29	12.10	0.70	0.46	17.62	
灌浆期	GPR	0.78	0.28	13.37	0.78	0.39	15.55	
	RFR	0.80	0.27	13.01	0.78	0.42	16.66	
	SVR	0.81	0.26	12.18	0.78	0.40	15.98	

与单一特征模型相比,特征融合模型在各生育期均显著提升了估算精度,表明颜色空间与纹理特征具有良好的互补性,验证了 RGB 传感器在低成本冬小麦氮素监测中的应用潜力。

2.2.2 基于多光谱影像特征估算冬小麦 LNC

本研究通过多光谱影像提取冬小麦 3 个生育期的冠层反射率,计算 11 个 VIs 作为光谱特征,结合相关性分析与 VIP 方法筛选关键变量。利用 GPR、RFR 和 SVR 模型构建冬小麦 LNC 估算模型,结果见表 4。验证结果表明,拔节期 R^2 为 0.59 ~ 0.60, RMSE 为 0.41% ~ 0.43%, NRMSE 为 18.64% ~ 19.46%; 开花期 R^2 为 0.65 ~ 0.69, RMSE 为 0.42% ~ 0.44%, NRMSE 为 16.30% ~ 16.87%; 灌浆期 R^2 为 0.77 ~ 0.79, RMSE 为 0.37% ~ 0.39%, NRMSE 为 14.56% ~ 15.25%。3 种模型在灌浆期的精度优于拔节期和开花期,验证 R^2 均大于 0.75,表明光谱特征能较好反映冬小麦 LNC 状况,拔节期的估算精度仍需提高。

表 4 光谱特征参数估算冬小麦 LNC 结果
Tab.4 Estimation of winter wheat LNC using spectral characteristic parameters

生育期	学习 方法	机器	建模集			验证集		
			R^2	RMSE/ %	NRMSE/ %	R^2	RMSE/ %	NRMSE/ %
拔节期	GPR	0.70	0.32	14.95	0.60	0.41	18.64	
	RFR	0.66	0.35	16.29	0.59	0.43	19.46	
	SVR	0.61	0.36	16.86	0.60	0.41	18.75	
开花期	GPR	0.74	0.33	13.62	0.69	0.42	16.30	
	RFR	0.77	0.31	12.79	0.65	0.42	16.32	
	SVR	0.74	0.33	13.80	0.66	0.44	16.87	
灌浆期	GPR	0.84	0.24	11.47	0.79	0.37	14.56	
	RFR	0.82	0.25	11.89	0.79	0.37	14.64	
	SVR	0.81	0.26	12.44	0.77	0.39	15.25	

2.3 融合无人机多源遥感信息估算冬小麦 LNC

研究表明,RGB 影像的颜色空间和纹理特征,以及多光谱影像的光谱特征均可有效用于冬小麦 LNC 的估算。RGB 传感器适合捕捉冠层细节,而多光谱传感器提供对植被生理状态敏感的红边和近红外波段信息。为突破单一传感器信息的局限,本研究融合 RGB 颜色空间与纹理特征和多光谱特征,构建了多源数据融合模型,其结果见表 5。尽管各类特征在构建阶段保持独立,但其在回归建模过程中通过同一学习器进行联合优化,模型参数能够自适应地学习不同特征对 LNC 的相对贡献,从而实现隐式融合。结果显示,SVR 模型在 3 个生育期中均表现最佳,验证 R^2 分别为 0.74(拔节期)、0.85(开花期)和 0.82(灌浆期),RMSE 分别为 0.36%、0.32% 和 0.35%,NRMSE 分别为 16.22%、12.41% 和 13.95%。与单一传感器模型相比,融合模型的估算精度显著提高。与 RGB 影像模型相比,融合模型在拔节期、开花期和灌浆期的 R^2 分别提高 0.06、0.13 和 0.04, RMSE 分别降低 0.02、0.10、0.04 个百分点, NRMSE 分别减少 1.04、3.90、1.60 个百分点;与仅使用多光谱影像的模型相比, R^2 分别提高 0.14、0.16 和 0.03, RMSE 分别降低 0.05、0.10、0.02 个百分点, NRMSE 分别减少 2.42、3.89、0.61 个百分点。这表明,RGB 和多光谱特征之间的互补性使得多源传感器信息融合显著提高了 LNC 估算的稳定性和准确性。为直观展示不同模型的估算表现,构建了基于建模集与验证集的预测值与实测值拟合图(图 6)。拟合图显示,各模型在不同生育期的估算精度存在差异,开花期的性能最佳。SVR 模型在各生育期的拟合优度更高,预测值接近 1:1 线,表现出在 LNC 估算中的精度优势。

表 5 融合无人机多源遥感信息估算冬小麦 LNC 结果
Tab.5 Estimation of winter wheat LNC using fused UAV multi-source remote sensing information

生育期	学习 方法	机器	建模集			验证集		
			R^2	RMSE/ %	NRMSE/ %	R^2	RMSE/ %	NRMSE/ %
拔节期	GPR	0.70	0.32	14.94	0.70	0.37	16.68	
	RFR	0.71	0.32	15.07	0.69	0.38	16.97	
	SVR	0.81	0.26	12.29	0.74	0.36	16.22	
开花期	GPR	0.90	0.20	8.42	0.81	0.34	13.28	
	RFR	0.93	0.18	7.31	0.82	0.35	13.58	
	SVR	0.91	0.20	8.14	0.85	0.32	12.41	
灌浆期	GPR	0.83	0.24	11.59	0.81	0.35	13.96	
	RFR	0.92	0.17	8.12	0.82	0.36	14.41	
	SVR	0.85	0.24	11.55	0.82	0.35	13.95	

2.4 冬小麦叶片氮含量空间分布

通过无人机遥感影像的预处理与拼接,获得




图 6 融合无人机多源遥感信息估算冬小麦 LNC 的实测值和预测值散点图与拟合曲线
Fig. 6 Scatter plots and fitting curves of measured and versus predicted values for winter wheat LNC estimation using fused UAV multi-source remote sensing information

了冬小麦在拔节期、开花期和灌浆期的高分辨率影像,并基于多源传感器信息融合构建了 LNC 监测模型,生成了叶片氮含量的空间分布图(图 7)。结果表明,拔节期的 LNC 预测值范围最大,开花期略低,灌浆期最低。不同生育期 LNC 在田间呈现显著空间变异,且随生育进程变化。氮肥梯度试验进一步证明,LNC 随着施氮量增加而提升,N0 处理下 LNC 始终较低且稳定。该基于多源信息融合的 LNC 监测方法具备非破坏性、广覆盖性和高空间分辨率,能为精准农业管理和氮肥施用策略优化提供科学依据。

3 讨论

3.1 颜色空间、纹理特征和光谱特征对 LNC 的贡献

作物在不同生长阶段的结构和组成变化会影响其冠层的反射特性,导致不同特征对 LNC 估算的响应敏感性差异。本研究构建了一种融合 RGB 颜色空间参数、纹理特征和多光谱特征的冬小麦 LNC 估算模型,并分析了各特征在不同生育阶段的贡献,以

识别关键影响因素,为作物理化参数估算和相关研究提供理论支持。本研究采用 SHAP (Shapley additive explanations)方法,通过计算 Shapley 值公平量化各变量对模型预测的贡献。SHAP 方法具有一致性强、适用性广等优点,已广泛应用于遥感回归模型的可解释性分析^[36]。图 8 展示了最优 SVR 模型在拔节期、开花期和灌浆期的特征参数平均绝对 SHAP 值及重要性排序。

结果表明,作物植被结构、叶片生理特性和土壤背景的变化共同影响了各特征变量对 LNC 估算的敏感性。在拔节期,植株处于快速生长期,NDRE、RVI 和颜色空间参数 u^* 的重要性较高;开花期时,叶面积指数达到最大值, u^* 参数对氮营养差异的响应增强;灌浆期,叶片衰老,RVI、NDRE 和 LCI 因能更准确反映叶片氮素状态,其重要性上升。综上,作物生长状态的变化显著影响遥感特征对 LNC 估算的响应能力。SHAP 方法不仅有效识别了关键影响变量,提升了模型可解释性,也为构建高精度、稳健的 LNC 估算模型提供了理论支持,推动精准农业管




图 7 LNC 空间分布图

Fig. 7 LNC spatial distribution map




图 8 特征参数的平均绝对 SHAP 值

Fig. 8 Average absolute SHAP values of characteristic parameters

4 结论

(1) 基于 RGB 和多光谱影像提取冬小麦的多源遥感特征,筛选最优变量并融合颜色空间、纹理及光谱特征参数,构建了 LNC 估算模型,系统评估了多源无人机传感器信息融合对估算精度的提升效果。

(2) 所构建的“两段式”特征筛选策略有效识别了 RGB 影像的颜色与纹理特征以及多光谱影像中

理和作物生长监测的发展。

3.2 多源信息融合在 LNC 估算中的优势

随着无人机遥感技术的进步,单一传感器(如 RGB 或多光谱)虽已广泛应用于作物表型与理化参数估测,但难以全面表征作物冠层的结构特征与生理状态^[37]。已有研究表明,多源遥感信息融合策略能有效互补单一维度的不足。例如,融合 RGB 与多光谱信息已被证明能显著提升作物氮素、SPAD 值及生物量的估算精度与稳定性^[38-40]。

本研究在前人基础上,采用了 RGB 颜色空间、纹理特征与多光谱特征的融合策略。本研究结果证实了该策略的有效性:相较于单一传感器模型,融合模型在各生育期的估算精度均有显著提升,验证集 R^2 提高了 0.03 ~ 0.16, RMSE 降低了 0.02 ~ 0.10 个百分点, NRMSE 减少了 0.61 ~ 3.90 个百分点。特别是在开花期,SVR 融合模型表现最佳 ($R^2 = 0.85$),显著优于单一光谱特征模型。这种提升主要得益于特征层的互补优势:RGB 影像的高分辨率纹理特征有效刻画了冠层结构与颜色细节,而多光谱影像的红边和近红外波段则提供了对氮素生理状态的高敏感性信息。通过同一学习器的联合优化,模型实现了对多源信息的隐式融合,从而在不引入复杂交互结构的前提下,显著增强了冬小麦 LNC 估算的鲁棒性。

的关键光谱特征,明确了不同生育期 LNC 估算的敏感变量,为后续多源特征融合建模提供了理论支持和参数依据。

(3) 基于筛选变量构建的单源传感器模型在不同生育期对冬小麦 LNC 具有一定的估算能力。拔节期验证 R^2 范围为 0.59 ~ 0.68, RMSE 范围为 0.38% ~ 0.41%, NRMSE 范围为 17.26% ~ 19.46%;开花期验证 R^2 范围为 0.65 ~ 0.72, RMSE 范围为 0.42% ~ 0.46%, NRMSE 范围为 16.31% ~

17.62% ;灌浆期验证 R^2 范围为 0.77 ~ 0.79 ,RMSE 范围为 0.37% ~ 0.42% ,NRMSE 范围为 14.56% ~ 16.66% 。

(4)多源传感器信息融合模型在各阶段的估算精度显著优于单一传感器模型。SVR 模型在所有生育期中表现最优,验证 R^2 分别为 0.74、0.85 和 0.82 ,RMSE 分别为 0.36%、0.32% 和 0.35% ,

NRMSE 分别为 16.22%、12.41% 和 13.95% 。与仅基于 RGB 或多光谱影像的模型相比,融合模型的 R^2 提高了 0.03 ~ 0.16 ,RMSE 降低了 0.02 ~ 0.10 个百分点,NRMSE 减少了 0.61 ~ 3.90 个百分点。结果表明,多源遥感特征的融合能够显著提升 LNC 估算模型的精度与稳定性,具有良好的应用前景。

参 考 文 献

[1] LIU M, WANG L, GAO M, et al. Monitoring leaf nitrogen concentration for different leaf layers based on multiangle remote sensing and fusion models[J]. Smart Agricultural Technology, 2025, 12: 101392.

[2] EUGENIO F C, GROHS M, SCHUH M S, et al. Flooded rice variables from high-resolution multispectral images and machine learning algorithms[J]. Remote Sensing Applications: Society and Environment, 2023, 31: 100998.

[3] HANK T B, BERGER K, BACH H, et al. Spaceborne imaging spectroscopy for sustainable agriculture: contributions and challenges[J]. Surveys in Geophysics, 2019, 40(3): 515 – 551.

[4] DIACONO M, RUBINO P, MONTEMURRO F. Precision nitrogen management of wheat. A review [J]. Agronomy for Sustainable Development, 2013, 33(1): 219 – 241.

[5] SUN W, WU Q, SUN X, et al. A novel inversion method of tobacco canopy nitrogen content based on vegetation index and color index[J]. Smart Agricultural Technology, 2025, 12: 101401.

[6] 贾丹, 陈鹏飞. 低空无人机影像分辨率对冬小麦氮浓度反演的影响[J]. 农业机械学报, 2020, 51(7): 164 – 169.

JIA Dan, CHEN Pengfei. Effects of low-altitude UAV image resolution on winter wheat nitrogen concentration inversion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 164 – 169. (in Chinese)

[7] 杨福芹, 李天驰, 冯海宽, 等. 基于无人机数码影像的冬小麦氮素营养诊断研究[J]. 福建农业学报, 2021, 36(3): 369 – 378.

YANG Fuqin, LI Tianchi, FENG Haikuan, et al. UAV digital image-assisted monitoring on nitrogen nutrition of winter wheat in the field[J]. Fujian Journal of Agricultural Sciences, 2021, 36(3): 369 – 378. (in Chinese)

[8] LU N, WANG W, ZHANG Q, et al. Estimation of nitrogen nutrition status in winter wheat from unmanned aerial vehicle based multi-angular multispectral imagery[J]. Frontiers in Plant Science, 2019, 10: 1601.

[9] ZHANG J, LIU X, LIANG Y, et al. Using a portable active sensor to monitor growth parameters and predict grain yield of winter wheat[J]. Sensors, 2019, 19(5): 1108.

[10] YANG B, WANG M, SHA Z, et al. Evaluation of aboveground nitrogen content of winter wheat using digital imagery of unmanned aerial vehicles[J]. Sensors, 2019, 19(20): 4416.

[11] SU X, NIAN Y, YUE H, et al. Improving wheat leaf nitrogen concentration (LNC) estimation across multiple growth stages using feature combination indices (FCIs) from UAV multispectral imagery[J]. Agronomy, 2024, 14(5): 1052.

[12] 史培华, 王远, 袁政奇, 等. 基于冠层 RGB 图像的冬小麦氮素营养指标监测[J]. 南京农业大学学报, 2020, 43(5): 829 – 837.

SHI Peihua, WANG Yuan, YUAN Zhengqi, et al. Estimation of wheat nitrogen nutrition indices in winter wheat based on canopy RGB images[J]. Journal of Nanjing Agricultural University, 2020, 43(5): 829 – 837. (in Chinese)

[13] LIU Y, YANG F, YUE J, et al. Crop canopy volume weighted by color parameters from UAV-based RGB imagery to estimate above-ground biomass of potatoes[J]. Computers and Electronics in Agriculture, 2024, 227: 109678.

[14] WANG F, YI Q, HU J, et al. Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102397.

[15] YUE J, YANG G, TIAN Q, et al. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150: 226 – 244.

[16] XUE J, SU B. Significant remote sensing vegetation indices: a review of developments and applications [J]. Journal of Sensors, 2017, 2017(1): 1353691.

[17] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction[J]. Remote Sensing of Environment, 2002, 80(1): 76 – 87.

[18] GITELSON A A, KAUFMAN Y J, MERZLYAK M N. Use of a green channel in remote sensing of global vegetation from EOS – MODIS[J]. Remote Sensing of Environment, 1996, 58(3): 289 – 298.

[19] FITZGERALD G J, RODRIGUEZ D, CHRISTENSEN L K, et al. Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments[J]. Precision Agriculture, 2006, 7(4): 233 – 248.

[20] DATT B. A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using eucalyptus leaves[J]. Journal of Plant Physiology, 1999, 154(1): 30 – 36.

[21] STEVEN M D. The sensitivity of the osavi vegetation index to observational parameters[J]. Remote Sensing of Environment, 1998, 63(1): 49 – 60.

[22] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. Remote Sensing of Environment, 1979, 8(2): 127 – 150.

[23] DORIGO W A, ZURITA-MILLA R, DE WIT A J W, et al. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling[J]. International Journal of Applied Earth Observation and Geoinformation, 2007, 9(2): 165 – 193.

[24] JIANG Z, HUETE A R, DIDAN K, et al. Development of a two-band enhanced vegetation index without a blue band[J]. Remote Sensing of Environment, 2008, 112(10): 3833 – 3845.

[25] DAUGHTRY C S T, WALTHALL C L, KIM M S, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance[J]. Remote Sensing of Environment, 2000, 74(2): 229 – 239.

[26] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications [J]. Canadian Journal of Remote Sensing, 1996, 22(3): 229 – 242.

[27] PREZA FONTES G, BHATTARAI R, CHRISTIANSON L E, et al. Combining environmental monitoring and remote sensing technologies to evaluate cropping system nitrogen dynamics at the field-scale[J]. Frontiers in Sustainable Food Systems, 2019, 3: 949.

[28] MAREMA Á, LLOVERAS J, MARTÍNEZ-CASASNOVAS J A. Use of multispectral airborne images to improve in-season nitrogen management, predict grain yield and estimate economic return of maize in irrigated high yielding environments[J]. Remote Sensing, 2018, 10(4): 543.

[29] 何嘉晨, 何敬, 王彬, 等. 基于无人机高光谱影像的水稻叶绿素含量反演[J]. 四川农业大学学报, 2024, 42(1): 174 – 180.
HE Jiachen, HE Jing, WANG Bin, et al. Inversion of chlorophyll content in rice based on UAV hyperspectral imagery[J]. Journal of Sichuan Agricultural University, 2024, 42(1): 174 – 180. (in Chinese)

[30] CHEN X, HUANG J, YI M. Cost estimation for general aviation aircrafts using regression models and variable importance in projection analysis[J]. Journal of Cleaner Production, 2020, 256: 120648.

[31] WANG S, GUAN K, WANG Z, et al. Unique contributions of chlorophyll and nitrogen to predict crop photosynthetic capacity from leaf spectroscopy[J]. Journal of Experimental Botany, 2020, 72(2): 341 – 354.

[32] HAN Y, TANG R, LIAO Z, et al. A novel hybrid GOA – XGB model for estimating wheat aboveground biomass using UAV – based multispectral vegetation indices[J]. Remote Sensing, 2022, 14(14): 3506.

[33] LEE J, KIM J, HAHN S-H, et al. Data-driven disruption prediction using random forest in KSTAR[J]. Fusion Engineering and Design, 2024, 199: 114128.

[34] SÁNCHEZ J C M, MESA H G A, ESPINOSA A T, et al. Improving wheat yield prediction through variable selection using support vector regression, random forest, and extreme gradient boosting[J]. Smart Agricultural Technology, 2025, 10: 100791.

[35] SHETTY S, SCHNEIDER P, STEBEL K, et al. Estimating surface NO₂ concentrations over Europe using Sentinel – 5P TROPOMI observations and machine learning[J]. Remote Sensing of Environment, 2024, 312: 114321.

[36] WANG Y, WANG P, TANSEY K, et al. An interpretable approach combining Shapley additive explanations and LightGBM based on data augmentation for improving wheat yield estimates[J]. Computers and Electronics in Agriculture, 2025, 229: 109758.

[37] MAIMAITIJANG 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: 111599.

[38] ZHU W, SUN Z, HUANG Y, et al. Optimization of multi-source UAV RS agro-monitoring schemes designed for field-scale crop phenotyping[J]. Precision Agriculture, 2021, 22(6): 1768 – 1802.

[39] HASSANI K, GHOLIZADEH H, TAGHVAEIAN S, et al. Application of UAS-Based remote sensing in estimating winter wheat phenotypic traits and yield during the growing season[J]. PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 2023, 91(2): 77 – 90.

[40] 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.