

基于无人机多光谱植被指数和纹理指数的马铃薯植株氮含量估算方法

杨福芹¹ 冯 皓² 孙晨明¹ 刘 杨³ 冯海宽⁴ 任建强⁵

(1. 河南工程学院土木工程学院, 郑州 451191; 2. 石河子大学城市与环境学院, 石河子 832003;

3. 河南农业大学信息与管理科学学院, 郑州 451191; 4. 北京市农林科学院信息技术研究中心, 北京 100097;

5. 中国农业科学院农业资源与农业区划研究所/北方干旱半干旱耕地高效利用全国重点实验室, 北京 100081)

摘要: 氮素是作物生长的重要元素之一,其精准监测对优化施肥和提高产量至关重要。本研究基于无人机多光谱及其变化特征开展马铃薯植株氮含量估算研究。获取了马铃薯块茎形成期、块茎增长期和淀粉积累期的多光谱影像,利用灰度共生矩阵提取多光谱影像上马铃薯的纹理特征,利用最优植被指数形式构建纹理植被指数,建立了纹理植被指数与植株氮含量的相关关系,以植被指数、纹理植被指数及其融合特征作为输入参数,使用人工神经网络、多元线性回归和偏最小二乘回归实现了不同生育期的马铃薯植株氮含量模型构建,并进行了验证。结果表明:在3个生育期达到极显著相关($P < 0.01$)的植被指数与植株氮含量的相关性在0.374~0.848之间,纹理植被指数与植株氮含量的相关性在0.625~0.855之间;以植被指数融合纹理植被指数为输入参数在3个生育期构建的马铃薯植株氮含量模型效果优于以植被指数及纹理植被指数为输入参数构建的植株氮含量模型,其建模的最大 R^2 和最小RMSE分别为0.859和0.228%,可以显著提高模型的精度和稳定性。相对于多元线性回归和偏最小二乘算法,人工神经网络估算马铃薯植株氮含量的精度最高。以植被指数为输入参数,利用人工神经网络平均建模的 R^2 和RMSE为0.806和0.231%,以纹理植被指数为输入参数,利用人工神经网络平均建模的 R^2 和RMSE为0.681和0.300%,以融合植被指数和纹理植被指数为输入参数,利用人工神经网络平均建模的 R^2 和RMSE为0.836和0.221%。该研究可为马铃薯氮含量快速反演及精准施肥提供技术支撑。

关键词: 植株氮含量; 马铃薯; 无人机遥感; 植被指数; 纹理特征

中图分类号: S25 文献标识码: A 文章编号: 1000-1298(2026)17-0144-08

OSID:



Estimation of Potato Plant Nitrogen Content Based on UAV Multispectral Vegetation Indices and Texture Indices

Yang Fuqin¹ Feng Hao² Sun Chenming¹ Liu Yang³ Feng Haikuan⁴ Ren Jianqiang⁵

(1. College of Civil Engineering, Henan University of Engineering, Zhengzhou 451191, China

2. College of Urban and Environmental Sciences, Shihezi University, Shihezi 832003, China

3. College of Information and Management Science, Henan Agricultural University, Zhengzhou 451191, China

4. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

5. Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences/

State Key Laboratory of Efficient Utilization of Arable Land in China, Beijing 100081, China)

Abstract: Nitrogen is a critical nutrient element for crop growth, and its accurate monitoring is essential for optimizing fertilization and improving yield. Aiming to develop an approach for estimating potato plant nitrogen content (PNC) by using unmanned aerial vehicle (UAV)-based multispectral imagery and its change characteristics, multispectral images were acquired during three key growth stages: tuber formation, tuber growth, and starch accumulation stage. The gray-level co-occurrence matrix (GLCM) method was applied to extract texture features from the multispectral images. Optimal vegetation indices

收稿日期: 2026-05-22 修回日期: 2026-06-01

基金项目: 国家自然科学基金项目(42571462)、河南省科技攻关项目(262102110349、202102310333)和中国博士后科学基金第78批面上项目(2025M782465)

作者简介: 杨福芹(1979—),女,副教授,博士,主要从事作物长势、养分监测和估产研究, E-mail: yangfuqin0202@163.com

通信作者: 冯海宽(1982—),男,副研究员,博士,主要从事作物长势、养分监测和估产研究, E-mail: fenghaikuan123@163.com

were selected to construct texture indices based on vegetation indices, and the correlation between the vegetation indices, texture vegetation indices and plant nitrogen content was established. Three types of input features, i. e. , the vegetation indices, texture vegetation indices and a fusion of vegetation indices and texture vegetation indices were used to build and validate estimation models for PNC at each growth stage. Three regression algorithms were compared: artificial neural network, multiple linear regression and partial least squares regression. Model performance was evaluated using the coefficient of determination (R^2) and root mean square error (RMSE). The results showed that during the three growth stages, the correlation between vegetation indices and plant nitrogen content reached a highly significant level ($P < 0.01$) ranged from 0.374 to 0.848, while the correlation between texture vegetation indices and plant nitrogen content ranged from 0.625 to 0.855, indicating that texture information improved the correlation. The potato plant nitrogen content model constructed by using fusion of vegetation index and texture vegetation index as input features outperformed the model built by using vegetation index and texture vegetation index alone. The highest R^2 and the smallest RMSE values for calibration and validation across the three stages were 0.859 and 0.228%, respectively, demonstrating that the fusion approach significantly enhanced model accuracy and stability. Compared with multiple linear regression and partial least squares algorithms, artificial neural networks had the highest accuracy in estimating nitrogen content in potato plants. When using vegetation index, texture vegetation index, and fusion vegetation index and texture vegetation index as input parameters, the average calibration R^2 and RMSE obtained by ANN were 0.806 and 0.231%, 0.681 and 0.300%, and 0.836 and 0.221%, respectively, in three critical stages. The proposed method, which integrated multispectral vegetation indices with texture features and employed ANN modeling, provided a reliable and efficient approach for rapid inversion of potato nitrogen content. This technique can support precision fertilization management in potato production.

Key words: plant nitrogen content; potato; UAV remote sensing; vegetation index; texture feature

0 引言

氮素为马铃薯生长过程中不可缺少的营养元素,合理施氮是保证马铃薯健康生长的重要物质基础^[1]。施用氮肥过量会导致植株过度生长,降低肥料利用率,施肥不足导致植株生长缓慢,产量下降。因此,准确获取马铃薯氮营养状况对评价氮素盈亏具有重要意义^[2]。传统氮含量的诊断方法主要依赖于样品的化学分析,取样量大,周期长而且成本高,难以满足大尺度的氮素监测需求^[3]。遥感技术的快速发展为高效、无损监测作物氮状况提供了新的技术手段^[4]。无人机作为遥感近地平台的搭载平台在农业方面得到了广泛的应用,其搭载的传感器主要有数码相机、多光谱相机和高光谱相机。多光谱相机不仅包含可见光波段,而且还包含对作物敏感的红边及近红外波段,相比数码相机和高光谱相机,在农业遥感中得到广泛应用。

目前,作物植株氮含量估算模型研究已经从简单的统计回归向“光谱特征工程+复杂机器学习/深度学习”转变,研究方法主要有基础统计回归模型(偏最小二乘回归、多元线性回归及岭回归等)、经典机器学习模型(支持向量回归、随机森林及高斯过程回归等)、深度学习模型(一维卷积神经网络等)及集成学习模型等,大多数研究者从单一指数

到多源特征融合,从统计模型到智能算法进行作物植株氮含量的估算。Fu 等^[5]探究了利用数码相机可见光波段、颜色参数和图像纹理特征,采用高斯过程回归和偏最小二乘回归算法估算冬小麦植株氮的营养状况。Li 等^[6]以颜色特征、纹理特征和温度为自变量,使用反向传播神经网络、随机森林和支持向量机进行冬小麦氮含量估算,结果表明基于颜色特征、纹理特征和温度相结合,利用随机森林估算氮含量模型最优。王宇唯等^[7]利用植被指数和纹理特征值及构建的纹理指数,采用随机森林算法进行水稻叶片氮含量估算,结果表明融合植被指数、纹理指数、纹理特征值和田间管理数据可以提高氮素监测精度。运彬媛等^[8]利用机器学习算法探究了无人机多光谱与纹理信息融合在玉米氮素营养估算中的应用,结果表明融合多光谱植被指数和纹理指数能够有效提高玉米氮素营养估测精度。樊意广等^[9]探究了光谱特征、图像特征和图谱融合特征估算马铃薯植株氮含量效果,结果表明以图谱融合特征为模型变量构建的植株氮含量模型精度和稳定性最好。有研究表明,获取的无人机冠层纹理特征在作物长势监测指标中也具有优越性。作物纹理特征直接反映了作物冠层的物理结构,能够揭示作物的健康和生长状况,纹理特征有助于反映作物的微观结构,可以更准确估算作物长势信息^[10-12]。

目前国内外学者在研究作物氮含量反演方面已有较多成果^[13-15],然而,利用植被指数、纹理特征以及纹理植被指数融合进行马铃薯植株氮含量估测模型相对较少。因此,本研究以无人机为遥感平台,获取马铃薯关键生育期多光谱影像,提取对植株氮含量敏感的植被指数及利用纹理特征采用敏感植被指数形式构建纹理特征植被指数,以植被指数、构建的纹理植被指数以及融合植被指数和纹理植被指数为输入参数,采用偏最小二乘法(Partial least squares regression, PLSR)、人工神经网络(Artificial neural network, ANN)和多元线性回归(Multiple linear regression analysis, MLR)方法构建马铃薯植株氮含量估算模型,以实现马铃薯氮营养状况的快速监测。

1 材料与方法

1.1 研究区概况与试验设计

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),该地年平均气温 11.8℃,平均年降水量 644 mm,属暖温带半湿润大陆性季风气候。设置 2 个早熟品种,分别为中薯 5(Z1)和中薯 3(Z2)。设置 3 个密度水平,分别为 T0:60 000 株/hm²;T1:72 000 株/hm²;T2: 84 000 株/hm²。4 种氮素水平,分别为 N0: 0 kg/hm²;N1:244.65 kg/hm²;N2:489.15 kg/hm²;N3:733.5 kg/hm²。3 种钾肥处理,分别为 K0: 0 kg/hm²;K1:970 kg/hm²(种植密度和氮素试验区以这种方式处理);K2:1 941 kg/hm²。田间管理措施与当地管理方法保持一致。试验田分为 48 个小区,单个小区面积为 5 m×6.5 m,具体方案见文献[9],试验区如图 1 所示。

1.2 无人机多光谱数据获取与处理

利用无人机搭载的 Parrot Sequoia 农业遥感专用四通道多光谱相机,分别于 2019 年 5 月 28 日(块茎形成期)、6 月 10 日(块茎增长期)和 6 月 20 日




图 1 研究区位置和试验田分区图

Fig. 1 Location of study area and layout of experimental plots

(淀粉积累期)获取马铃薯遥感影像长势信息。多光谱相机参数如表 1 所示。为保证多光谱影像质量,选择无风、无云的正午(12:00—14:00)进行固定飞行航线的飞行作业,飞行高度设置为 20 m。无人机在关键生育期飞行前,需要进行白板校正,用于像元亮度值的标定。

表 1 多光谱相机波段参数

Tab. 1 Band parameters of multi-spectral camera		
波段	中心波长/nm	带宽/nm
绿 GRE	550	40
红 RED	660	40
红边 REG	735	10
近红外 NIR	790	40

将选取的多光谱影像导入到 Agisoft PhotoScan Professional 软件中,利用地面控制点对影像进行对齐、校正,基于密集点云生成试验区的数字正射影像(Digital orthophoto map, DOM)。将处理过的影像导入到 ENVI 5.1 软件中获取各波段的反射率影像,绘制出每个小区感兴趣区域,分别计算统计出每个小区在各波段的平均反射率,最后将其作为各小区在该波段下的光谱反射率。

1.3 地面观测数据获取

每个试验区破坏性选取能代表整体长势水平的 3 棵马铃薯植株,茎、叶和块茎分离后分别放入纸袋中,105℃杀青 30 min,然后 80℃烘干至质量恒定,用精度为 0.01 g 的天平称量烘干后的叶干质量和

茎干质量。用凯氏定氮仪分别测定马铃薯叶片氮含量和地上茎氮含量,计算马铃薯植株氮含量

$$C_{PNC} = \frac{M_{LDM}C_{LNC} + M_{SDM}C_{SNC}}{M_{LDM} + M_{SDM}} \times 100\%$$

- 式中 C_{PNC} ——马铃薯植株氮质量分数,%
 M_{LDM} ——烘干后的叶干质量,kg/hm²
 C_{LNC} ——马铃薯叶片氮质量分数,%
 M_{SDM} ——茎干质量,kg/hm²
 C_{SNC} ——地上茎氮质量分数,%

1.4 植被指数选取

本研究选取由多光谱波段反射率值采用线性及非线性构成的 18 个植被指数 (Vegetation index, VI) 进行马铃薯植株氮含量反演,具体为比值植被指数 (RVI)、土壤调整植被指数 (SAVI)^[16]、改进简单比值植被指数 (MSR)、绿波段归一化差值植被指数 (GNDVI)、优化土壤调节植被指数 (OSAVI)、归一化植被指数 (NDVI)^[17]、非线性植被指数 (NLI)、差值植被指数 (DVI)、重归一化差异植被指数 (RDVI)^[18]、绿红黄比值植被指数 (RGRI)^[19]、绿色比值植被指数 (GRVI)^[20]、归一化绿红差分植被指数 (NGRDI)^[21]、叶面叶绿素含量指数 (LCI)^[22]、归一化差异红边植被指数 (NDRE)^[23]、归一化差分水体指数 (NDWI)^[24]、改进的叶绿素吸收率指数 (MCARI)、植被衰减指数 (PSRI)和绿色指数 (GI)^[25]。

1.5 多光谱纹理特征提取

利用 ENVI 5.3 灰度共生矩阵 (Gray-level co-occurrence matrix, GLCM) 对多光谱红、绿、红边、近红外 4 个波段进行纹理特征提取^[26],在 45°方向上使用窗口大小 3×3 得到 4 个波段的 8 个纹理特征,分别是均值 (mean)、方差 (variance, var)、同质性 (homogeneity, hom)、对比度 (contrast, con)、相异性 (dissimilarity, dis)、信息熵 (entropy, ent)、二阶矩 (second moment, sec) 和相关性 (correlation, cor)。单波段纹理信息能削弱光照条件、大气状况及传感器差异等外界因素的影响,多波段纹理特征可以包含更丰富的作物信息,利用逐波段纹理特征组合构建不同波段的纹理特征植被指数 (Texture vegetation index, TVI)。根据植被指数与植株氮含量相关性筛选出相关性高的 6 个植被指数,利用逐波段组合构建不同的纹理植被指数。

1.6 植株氮含量估算模型构建

研究采用偏最小二乘回归法 (PLSR)、人工神经网络 (ANN) 和多元线性回归分析 (MLR) 算法进行植株氮含量建模。PLSR 是集主成分分析、多元线性回归和典型相关性分析为一体的多元统计建模方法,能够在自变量个数多、样本量少及变量存在共线

性的情况下,在保持模型稳健的同时实现模型的精准预测^[27]。ANN 通过模拟人脑神经网络的信息处理机制,利用反向传播算法等训练机制,能够从大量数据中自动提取复杂特征,实现从输入到输出的精准映射,无需预设具体的函数形式,可以学习和适应各种复杂的模式和关系^[28]。MLR 通过最小二乘法估计回归系数,以最小化观测值与拟合值之间的残差平方和,从而实现对因变量的预测与影响因素的重要性分析^[29]。该模型形式简洁、参数估计明确,且具有较强的可解释性。

1.7 精度评价指标

采用决定系数 (Coefficient of determination, R^2) 和均方根误差 (Root mean square error, RMSE) 作为反演植株氮含量模型精度的评价指标, R^2 越接近于 1,表明模型整体拟合效果越好, RMSE 越接近 0,说明预测结果越接近实测值^[30]。

2 结果与分析

2.1 植株氮含量与多光谱植被指数相关性分析

表 2 分析了植被指数与植株的氮含量相关性。在块茎形成期,植被指数与植株氮含量都达到了极显著相关 ($P < 0.01$),相关系数在 0.374 ~ 0.848 范围内,相关性最好的植被指数是 MCARI。在块茎增长期和淀粉积累期, LCI 和 NDRE 与植株氮含量均

表 2 植被指数与马铃薯植株氮含量的相关系数 ($n = 48$)

Tab.2 Correlation between vegetation index and potato nitrogen content ($n = 48$)			
植被指数	块茎形成期	块茎增长期	淀粉积累期
RVI	0.714 **	0.762 **	0.570 **
MSR	0.703 **	0.760 **	0.575 **
GNDVI	0.748 **	0.812 **	0.713 **
NLI	0.691 **	0.761 **	0.579 **
SAVI	0.685 **	0.750 **	0.578 **
RDVI	0.686 **	0.751 **	0.578 **
OSAVI	0.680 **	0.746 **	0.576 **
DVI	0.693 **	0.757 **	0.577 **
NDVI	0.675 **	0.742 **	0.578 **
RGRI	0.594 **	0.680 **	0.324 *
GRVI	0.774 **	0.818 **	0.710 **
NGRDI	0.591 **	0.664 **	0.322 *
LCI	0.512 **	0.001 ^{NS}	0.173 ^{NS}
NDRE	0.374 **	0.131 ^{NS}	0.178 ^{NS}
NDWI	0.750 **	0.812 **	0.713 **
MCARI	0.848 **	0.759 **	0.514 **
PSRI	0.669 **	0.509 **	0.480 **
GI	0.594 **	0.680 **	0.324 *

注: ** 表示 0.01 水平显著, * 表示 0.05 水平显著, NS 表示不显著。下同。

没有达到极显著相关($P < 0.01$)。在块茎增长期, 植被指数与植株氮含量都达到了极显著相关($P < 0.01$), 相关系数在 0.509 ~ 0.812 范围内, 与植株氮含量相关性最好的植被指数是 GRVI。在淀粉积累期, 植被指数 NGRDI、RGRI 和 GI 与植株氮含量达到显著相关($P < 0.05$), 其他植被指数与植株氮含量都达到了极显著相关($P < 0.01$), 相关系数在 0.480 ~ 0.713 范围内, 其中与植株氮含量相关性最好的植被指数是 GRVI。综合考虑 3 个关键生育期植被指数与植株氮含量的相关系数, 选取 GNDVI、GRVI、NDWI、RVI、MSR 和 DVI 作为马铃薯植株氮含量的输入参数。

2.2 纹理植被指数的构建及与植株氮含量的相关性分析

根据植被指数与植株氮含量相关性筛选出相关性高的 6 个植被指数 GNDVI、GRVI、NDWI、RVI、MSR 和 DVI, 利用逐波段组合参考植被指数 GNDVI、GRVI、NDWI、RVI、MSR 和 DVI 构建不同的纹理植被指数。表 3 分析了每种纹理植被指数与植株氮含量最高的相关系数。可以看出, 筛选出的纹理植被指数与植株氮含量达到了极显著相关($P < 0.01$), 块茎形成期相关性最高的纹理植被指数为 GRVI(NIR-mean, GRE-cor), 其值为 0.822。块茎增长期相关性最高的纹理植被指数为 GRVI(NIR-con, GRE-var), 其值为 0.855。淀粉积累期相关性最高的纹理植被指数为 GNDVI(NIR-dis, GRE-mean) 和

表 3 纹理植被指数与马铃薯植株氮含量的相关性 ($n = 48$)

Tab.3 Correlation between texture vegetation index and potato nitrogen content ($n = 48$)		
生育期	植被指数	相关系数
块茎形成期	GNDVI (NIR-dis, GRE-cor)	0.819 **
	GRVI (NIR-mean, GRE-cor)	0.822 **
	NDWI (GRE-cor, NIR-con)	0.809 **
	RVI (NIR-mean, RED-cor)	0.800 **
	MSR (NIR-mean, RED-cor)	0.800 **
	DVI (NIR-con, RED-mean)	0.748 **
块茎增长期	GNDVI (NIR-con, GRE-var)	0.846 **
	GRVI (NIR-con, GRE-var)	0.855 **
	NDWI (GRE-var, NIR-con)	0.845 **
	RVI (NIR-con, RED-ent)	0.798 **
	MSR (NIR-con, RED-ent)	0.800 **
	DVI (NIR-var, RED-ent)	0.796 **
淀粉积累期	GNDVI (NIR-dis, GRE-mean)	0.680 **
	GRVI (NIR-dis, GRE-mean)	0.679 **
	NDWI (GRE-mean, NIR-dis)	0.680 **
	RVI (NIR-con, RED-ent)	0.627 **
	MSR (NIR-con, RED-ent)	0.630 **
	DVI (NIR-con, RED-ent)	0.625 **

NDWI (GRE-mean, NIR-dis), 其值均为 0.680。

2.3 基于不同参数的马铃薯植株氮含量估算

以植被指数 GNDVI、GRVI、NDWI、RVI、MSR、DVI, 块茎形成期纹理植被指数 GNDVI (NIR-dis, GRE-cor)、GRVI (NIR-mean, GRE-cor)、NDWI (GRE-cor, NIR-con)、RVI (NIR-mean, RED-cor)、MSR (NIR-mean, RED-cor)、DVI (NIR-con, RED-mean), 块茎增长期植被指数 GNDVI (NIR-con, GRE-var)、GRVI (NIR-con, GRE-var)、NDWI (GRE-var, NIR-con)、RVI (NIR-con, RED-ent)、MSR (NIR-con, RED-ent)、DVI (NIR-var, RED-ent), 淀粉积累期植被指数 GNDVI (NIR-dis, GRE-mean)、GRVI (NIR-dis, GRE-mean)、NDWI (GRE-mean, NIR-dis)、RVI (NIR-con, RED-ent)、MSR (NIR-con, RED-ent)、DVI (NIR-con, RED-ent), 以及植被指数融合纹理植被指数为输入因子, 利用 PLSR、ANN 和 MLR 算法构建植株氮含量模型, 结果如表 4 所示。从表中可以看出, 以植被指数融合纹理植被指数为输入参数构建的马铃薯植株氮含量模型最优 (PLSR 平均建模的 R^2 和 RMSE 为 0.747 和 0.275%, ANN 平均建模的 R^2 和 RMSE 为 0.836 和 0.221%, MLR 平均建模的 R^2 和 RMSE 为 0.827 和 0.269%), 以植被指数为输入参数次之 (PLSR 平均建模的 R^2 和 RMSE 为 0.715 和 0.316%, ANN 平均建模的 R^2 和 RMSE 为 0.806 和 0.231%, MLR 平均建模的 R^2 和 RMSE 为 0.792 和 0.283%), 纹理植被指数为输入参数最差 (PLSR 平均建模的 R^2 和 RMSE 为 0.682 和 0.298%, ANN 平均建模的 R^2 和 RMSE 为 0.681 和 0.300%, MLR 平均建模的 R^2 和 RMSE 为 0.693 和 0.385%)。块茎形成期, 用 ANN 方法构建的马铃薯植株氮含量模型建模精度 (R^2 分别为 0.833、0.769 和 0.859) 优于用 MLR (R^2 分别为 0.828、0.754 和 0.844) 方法及 PLSR (R^2 分别为 0.753、0.706 和 0.765) 方法。块茎增长期, 以纹理植被指数及植被指数融合纹理植被指数为输入参数, 用 MLR 方法建模精度 (R^2 分别为 0.820 和 0.863) 优于 ANN (R^2 分别为 0.808 和 0.851) 和 PLSR (R^2 分别为 0.759 和 0.774) 方法。以植被指数为输入参数, 用 ANN 方法建模的精度 (R^2 为 0.819) 优于 MLR (R^2 为 0.796) 和 PLSR (R^2 为 0.704) 方法。淀粉积累期, 以植被指数及植被指数融合纹理植被指数为输入参数, 用 ANN 方法建模精度 (R^2 分别为 0.766 和 0.797) 优于 MLR (R^2 分别为 0.752 和 0.775) 和 PLSR (R^2 分别为 0.689 和 0.703) 方法, 以纹理植被指数为输入参数, 用 PLSR 方法建模精度 (R^2 为 0.581) 优于 ANN (R^2 为 0.467) 和 MLR (R^2 为 0.505) 方法。

表 4 不同模型结果对比 (n = 48)

Tab. 4 Comparison of results by different models (n = 48)

算法	参数	块茎形成期				块茎增长期				淀粉积累期			
		建模		验证		建模		验证		建模		验证	
		R ²	RMSE/%	R ²	RMSE/%	R ²	RMSE/%	R ²	RMSE/%	R ²	RMSE/%	R ²	RMSE/%
PLSR	VI	0.753	0.320	0.703	0.299	0.704	0.322	0.655	0.321	0.689	0.306	0.658	0.306
	TVI	0.706	0.334	0.699	0.404	0.759	0.282	0.676	0.336	0.581	0.278	0.534	0.423
	VI + TVI	0.765	0.282	0.732	0.400	0.774	0.271	0.737	0.347	0.703	0.273	0.679	0.357
ANN	VI	0.833	0.246	0.717	0.549	0.819	0.197	0.571	0.388	0.766	0.251	0.577	0.266
	TVI	0.769	0.292	0.544	0.510	0.808	0.267	0.554	0.352	0.467	0.340	0.449	0.275
	VI + TVI	0.859	0.228	0.799	0.254	0.851	0.227	0.689	0.289	0.797	0.207	0.696	0.206
MLR	VI	0.828	0.356	0.741	0.599	0.796	0.262	0.617	0.360	0.752	0.230	0.471	0.755
	TVI	0.754	0.409	0.498	0.520	0.820	0.321	0.573	0.429	0.505	0.424	0.447	0.292
	VI + TVI	0.844	0.239	0.798	0.255	0.863	0.286	0.681	0.677	0.775	0.282	0.635	0.260

注:VI 表示植被指数,TVI 表示纹理植被指数,VI + TVI 表示植被指数 + 纹理植被指数。

3 讨论

本研究使用无人机多光谱植被指数和纹理植被指数进行马铃薯植株氮含量估算。结果表明,融合植被指数与纹理植被指数的模型精度显著优于单一特征模型,这是因为植被指数提供了马铃薯冠层光谱信息,主要反映作物的叶绿素含量及光合潜力,但在冠层封垄后极易产生光谱饱和现象。而纹理植被指数提供了马铃薯二维空间纹理信息,能够量化像元间的空间排列规律,捕捉叶片分布、孔隙度及阴影模式等冠层结构异质性。这种光谱信息(生化成分)与空间特征(物理结构)的互补,有效弥补了单一信息的局限性。两者数据融合构建的模型在估算马铃薯氮含量时表现出更高的估测精度和泛化能力,这与近年来多项研究结论高度一致。王宇唯等^[7]在研究水稻氮含量时发现,融合植被指数、纹理信息及地面观测的多模态数据进行水稻氮含量的估算模型优于单一无人机遥感估算模型。鲁星星等^[31]在大豆叶绿素估算中也证实,纹理与光谱信息的组合能提供更全面的生理结构描述。

在模型构建方面,研究发现人工神经网络(ANN)的估算精度优于多元线性回归(MLR)和偏最小二乘回归(PLSR),虽然传统回归方法具有模型简单、物理意义明确的优点,但鉴于植株冠层光谱与氮含量之间复杂的非线性响应机制,以及高光谱数据固有的多重共线性问题,本研究采用机器学习算法以期获得更高的估算精度和模型鲁棒性。Zhang 等^[32]在冬小麦研究中指出,光谱与纹理特征之间存在复杂的交互关系,传统的线性回归难以完全挖掘其内在逻辑。与刘杰等^[33]采用的支持向量机(SVR)相比,ANN 具有更强的非线性映射能力。

融合特征显著提升了估算精度,但仍存在一定的局限。如马铃薯在生育后期受植株枯萎和土壤背景露出的影响,光谱响应也会产生偏差。本研究主要关注了多光谱及纹理特征,未来应引入更多的结构参数(如株高、生物量)或利用激光雷达(LiDAR)数据获取更精准的三维结构信息,以进一步提升马铃薯氮含量监测在不同环境和品种下的普适性。

4 结论

(1)利用无人机平台搭载多光谱传感器,获取了马铃薯 3 个关键生育期的多光谱影像,以植被指数、纹理植被指数以及融合植被指数和纹理植被指数为输入参数,采用 ANN、MLR 和 PLSR 构建了马铃薯植株氮含量估算模型。该研究提出的融合植被指数和纹理指数加人工神经网络进行马铃薯植株氮含量估算,可为马铃薯氮含量的快速反演及马铃薯精准施肥管理提供技术支撑。

(2)马铃薯在块茎形成期、块茎增长期和淀粉积累期达到极显著相关($P < 0.01$)的植被指数与植株氮含量的相关性在 0.374 ~ 0.848 之间,优选后的纹理植被指数与植株氮含量的相关性在 0.625 ~ 0.855 之间。

(3)融合植被指数和纹理植被指数可以显著提高模型的精度和稳定性,3 个关键生育期 ANN 构建的马铃薯植株氮含量模型精度最高,块茎形成期建模和验证的 R^2 和 RMSE 分别为 0.859、0.228% 和 0.799、0.254%;块茎增长期建模和验证的 R^2 和 RMSE 分别为 0.851、0.227% 和 0.689、0.289%;淀粉积累期建模和验证的 R^2 和 RMSE 分别为 0.797、0.207% 和 0.696、0.206%。

参 考 文 献

[1] Han S, Zhao Y, Cheng J, et al. Monitoring key wheat growth variables by integrating phenology and UAV multispectral imagery data into random forest model[J]. Remote Sensing, 2022, 14(15): 3723.

[2] Berger K, Verrelst J, Feret J B, et al. Crop nitrogen monitoring: recent progress and principal developments in the context of imaging spectroscopy missions[J]. Remote Sensing of Environment, 2020, 242: 111758.

[3] 朱格格, 王清华, 吴海亚, 等. 基于可解释机器学习的冬油菜叶片氮、磷、钾含量遥感估测[J]. 农业机械学报, 2026, 57(8): 344 – 354.

Zhu Gege, Wang Qinghua, Wu Haiya, et al. Linking leaf phenotypes to spectral characteristics for remote estimation of leaf nitrogen, phosphorous, and potassium concentration in winter oilseed rape (*Brassica napus* L.) [J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(8): 344 – 354. (in Chinese)

[4] 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.

[5] Fu Y, Yang G, Li Z, et al. Winter wheat nitrogen status estimation using UAV based RGB imagery and Gaussian processes regression[J]. Remote Sensing, 2020, 12(22): 3778.

[6] Li R, Wang D, Zhu B, et al. Estimation of nitrogen content in wheat using indices derived from RGB and thermal infrared imaging[J]. Field Crops Research, 2022, 289: 108735.

[7] 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 CSAE, 2024, 40(18): 100 – 109. (in Chinese)

[8] 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. Estimation of maize nitrogen nutrition by integrating UAV spectral and texture information[J]. Scientia Agricultura Sinica, 2024, 57(16): 3154 – 3170. (in Chinese)

[9] 樊意广, 冯海宽, 刘杨, 等. 基于无人机成像高光谱估算马铃薯植株氮含量[J]. 光谱学与光谱分析, 2023, 43(5): 1524 – 1531.

Fan Yiguang, Feng Haikuan, Liu Yang, et al. Estimation of potato plant nitrogen content based on UAV hyperspectral imaging[J]. Spectroscopy and Spectral Analysis, 2023, 43(5): 1524 – 1531. (in Chinese)

[10] Zheng H, Ma J, Zhou M, et al. Enhancing the nitrogen signals of rice canopies across critical growth stages through the integration of textural and spectral information from unmanned aerial vehicle (UAV) multispectral imagery[J]. Remote Sensing, 2020, 12(6): 957.

[11] Zheng H, Cheng T, Li D, et al. Combining unmanned aerial vehicle (UAV) based multispectral imagery and ground based hyperspectral data for plant nitrogen concentration estimation in rice[J]. Frontiers in Plant Science, 2018, 9: 936.

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

[13] 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)

[14] 郭发旭, 冯金, 杨森, 等. 基于无人机高光谱的马铃薯冠层叶片全氮含量反演[J]. 浙江农业学报, 2023, 35(8): 1904 – 1914.

Guo Faxu, Feng Jin, Yang Sen, et al. Estimation of potato canopy leaf total nitrogen content based on UAV hyperspectral[J]. Acta Agriculture Zhejiangensis, 2023, 43(5): 1904 – 1914. (in Chinese)

[15] 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 transfer ability of the models in winter wheat plant[J]. Scientia Agricultura Sinica, 2023, 56(5): 850 – 865. (in Chinese)

[16] Brinkhoff J, Dunn B W, Robson A J, et al. Modeling mid-season rice nitrogen uptake using multispectral satellite data[J]. Remote Sensing, 2019, 11(15): 1837.

[17] Qi H, Zhu B, Wu Z, et al. Estimation of peanut leaf area index from unmanned aerial vehicle multispectral images[J]. Sensors, 2020, 20(23): 6732.

[18] Wan L, Li Y, Cen H, et al. Combining UAV based vegetation indices and image classification to estimate flower number in oilseed rape[J]. Remote Sensing, 2018, 10(9): 1484.

[19] Ballester C, Brinkhoff J, Quayle W C, et al. Monitoring the effects of water stress in cotton using the green red vegetation index and red edge ratio[J]. Remote Sensing, 2019, 11(7): 873.

[20] 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: 927.

[21] Hunt E R, Horneck D A, Spinelli C B, et al. Monitoring nitrogen status of potatoes using small unmanned aerial vehicles[J]. Precision Agriculture, 2018, 19(2): 314 – 333.

[22] Kaur R, Singh B, Singh M, et al. Hyperspectral indices, correlation and regression models for estimating growth parameters of wheat genotypes[J]. Journal of the Indian Society of Remote Sensing, 2015, 43(3): 551 – 558.

[23] 徐一高. 基于无人机多光谱影像的大豆冠层叶绿素和氮元素含量的反演研究[D]. 郑州:河南农业大学,2023.

Xu Yigao. Inversion of soybean canopy chlorophyll and nitrogen content based on UAV multispectral imagery[D]. Zhengzhou: Henan Agricultural University,2023. (in Chinese)

[24] 王纪华, 赵春江, 黄文江, 等. 农业定量遥感基础与应用[M]. 北京: 科学出版社, 2008.

[25] 罗小波, 谢天授, 董圣贤. 基于无人机多光谱影像的柑橘冠层叶绿素含量反演[J]. 农业机械学报, 2023, 54(4): 198 – 205.

Luo Xiaobo, Xie Tianshou, Dong Shengxian. Estimation of citrus canopy chlorophyll based on UAV multispectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 198 – 205. (in Chinese)

[26] 郭立笑, 陈志超, 马彦鹏, 等. 基于无人机多光谱和多波段组合纹理的马铃薯 LAI 估算[J]. 光谱学与光谱分析, 2024, 44(12): 3443 – 3454.

Guo Lixiao, Chen Zhichao, Ma Yanpeng, et al. Estimation of potato LAI using UAV multispectral and multiband combined textures[J]. Spectroscopy and Spectral Analysis, 2024, 44(12): 3443 – 3454. (in Chinese)

[27] Nile W, Rina S, Mula N, et al. Inversion of leaf chlorophyll content in different growth periods of maize based on multi-source data from “sky-space-ground”[J]. Remote Sensing, 2025, 17(4): 572.

[28] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359 – 366.

[29] Montgomery D C, Peck E A, Vining G G. Introduction to linear regression analysis[M]. 5th ed. Hoboken: John Wiley & Sons, 2012: 1 – 25.

[30] Willmott C J, Matsuura K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance[J]. Climate Research, 2005, 30(1): 79 – 82.

[31] 鲁星星, 向友珍, 李志军, 等. 基于无人机纹理指数的大豆叶绿素含量估算模型[J]. 农业机械学报, 2025, 56(11): 632 – 639.

Lu Xingxing, Xiang Youzhen, Li Zhijun, et al. Estimation model of soybean chlorophyll content based on UAV texture index [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 632 – 639. (in Chinese)

[32] Zhang J, Cheng T, Shi L, et al. Combining spectral and texture features of UAV hyperspectral images for leaf nitrogen content monitoring in winter wheat[J]. International Journal of Remote Sensing, 2022, 43(7): 2335 – 2356.

[33] 刘杰, 国佳欣, 张嘉豪, 等. 基于植被指数和纹理特征融合的冬油菜叶面积指数估测方法[J]. 智慧农业(中英文), 2025, 7(6): 161 – 173.

Liu Jie, Guo Jiaxin, Zhang Jiahao, et al. Method for estimating leaf area index of winter rapeseed based on fusion of vegetation indices and texture features[J]. Smart Agriculture, 2025, 7(6): 161 – 173. (in Chinese)