

基于无人机-卫星影像尺度转换的谷子关键生育期 叶绿素相对含量反演方法

谢佳希¹ 赵 丽² 周子轩³ 牛艺淳² 宋鑫铭¹ 于 洁²

(1. 河北农业大学资源与环境科学学院, 保定 071000; 2. 河北农业大学国土资源学院, 保定 071000;
3. 河北农业大学机电工程学院, 保定 071000)

摘要: 叶绿素相对含量 (SPAD) 是评估谷子生长势态与氮素营养状况的关键指标。为实现谷子关键生育期 (拔节期、抽穗期、灌浆期、成熟期) 叶绿素相对含量的高精度、广覆盖动态监测, 本研究融合田块尺度的无人机与卫星多源遥感数据, 提出一种基于改进灰狼优化算法 (IGWO) 优化长短期记忆神经网络 (LSTM) 的叶绿素相对含量反演模型。同步获取各关键生育期的无人机遥感数据、卫星遥感数据及地面点状 SPAD 实测值, 通过地面实测样点的经纬度坐标, 将点状 SPAD 值与对应位置的无人机影像像元、卫星影像像元进行空间匹配关联, 构建影像-实测对应数据集; 采用点扩散函数法 (Point spread function, PSF) 进行无人机影像的尺度上推, 结合均值-方差法对卫星数据进行初步修正, 再利用支持向量回归 (Support vector regression, SVR) 建立无人机-卫星多源遥感数据协同校正模型; 基于校正后的高精度卫星数据, 通过皮尔逊相关性分析与 XG-Boost 特征重要性排序, 筛选对叶绿素相对含量敏感的光谱特征参数; 引入非线性收敛因子提升灰狼优化算法的超参数寻优能力, 最终构建 IGWO-LSTM 叶绿素相对含量反演模型。结果表明, 相较于其他重采样方法, 点扩散函数法在升尺度过程中信息损失最小, 处理后影像像元的平均值与标准差分别为 0.103 和 0.056; 经直方图匹配法校正后的卫星遥感数据有效保持原始光谱形状, 光谱角映射值 (Spectral angle mapper, SAM) 低至 0.062°; SVR 算法在关键生育期的 B/G/R/NIR 波段校正模型精度均最高, 四波段决定系数分别为 0.920、0.961、0.963、0.900; IGWO-LSTM 模型在关键生育期叶绿素相对含量反演中的决定系数 (R^2) 达 0.985, 均方根误差 (RMSE) 为 0.111, 显著优于偏最小二乘回归 (PLSR)、BP 神经网络 (BPNN) 及随机森林回归 (RF) 等传统模型。本研究实现了谷子关键生育期叶绿素相对含量的精准动态反演, 对作物生长智能监测与氮肥精准施用具有重要意义。

关键词: 谷子; 叶绿素相对含量; 尺度转换; 无人机; 卫星遥感; 协同校正模型

中图分类号: S515; TP79 文献标识码: A 文章编号: 1000-1298(2026)01-0169-11

OSID:



Inversion Method of Chlorophyll Relative Content in Key Growth Stages of Millet Based on Unmanned Aerial Vehicle – Satellite Image Scale Conversion

XIE Jiayi¹ ZHAO Li² ZHOU Zixuan³ NIU Yichun² SONG Xinming¹ YU Jie²

(1. College of Resources and Environmental Sciences, Hebei Agricultural University, Baoding 071000, China
2. College of Land and Resources, Hebei Agricultural University, Baoding 071000, China
3. College of Mechanical and Electrical Engineering, Hebei Agricultural University, Baoding 071000, China)

Abstract: SPAD is a key indicator for evaluating the growth potential and nitrogen nutrition status of millet. To achieve high-precision and wide-coverage dynamic monitoring of the relative chlorophyll content of millet during key growth stages (jointing stage, heading stage, filling stage, and maturity stage), taking the field scale as the research area and integrated multi-source remote sensing data from unmanned aerial vehicles (UAV) and satellites, an SPAD inversion model for optimizing long short-term memory neural networks (LSTM) based on the improved grey wolf optimization algorithm (IGWO) was proposed. During the research process, UAV remote sensing data, satellite remote sensing data and ground point-like SPAD measured values of each key growth period were obtained simultaneously.

收稿日期: 2025-09-10 修回日期: 2025-10-15

基金项目: 河北省重点研发计划项目 (19226421D)

作者简介: 谢佳希 (2000—), 女, 硕士生, 主要从事农业遥感技术应用研究, E-mail: 2216798012@qq.com

通信作者: 赵丽 (1981—), 女, 教授, 博士, 主要从事土地生态和资源利用研究, E-mail: zhaoli@hebau.edu.cn

Through the longitude and latitude coordinates of the ground measured sample points, the point-like SPAD values were spatially matched and associated with the UAV image pixels and satellite image pixels at the corresponding positions to construct an image-measured corresponding data set. The point spread function (PSF) method was adopted for scale upward inference of UAV images. The mean-variance method was combined to preliminarily correct the satellite data. Then the support vector regression (SVR) was used to establish a collaborative correction model for multi-source remote sensing data of UAV and satellite. Based on the corrected high-precision satellite data, the spectral characteristic parameters sensitive to SPAD were screened through Pearson correlation analysis and XG-Boost feature importance ranking. The nonlinear convergence factor was introduced to enhance the hyperparameter optimization ability of the grey wolf optimization algorithm, and finally the IGWO-LSTM SPAD inversion model was constructed. The results showed that compared with other resampling methods, the point spread function method had the least information loss during the scale-up process. The average value and standard deviation of the processed image pixels were 0.103 and 0.056, respectively. The satellite remote sensing data corrected by the histogram matching method effectively retained the original spectral shape, and the spectral angle mapping value (SAM) was as low as 0.062°. The SVR algorithm had the highest model accuracy in the B/G/R/NIR bands during the critical growth period, and the determination coefficients of the four bands were 0.920, 0.961, 0.963 and 0.900, respectively. The coefficient of determination (R^2) of the IGWO-LSTM model in the inversion of SPAD during the critical growth period reached 0.985, and the root mean square error (RMSE) was 0.111, which was significantly superior to that of traditional models such as partial least squares regression (PLSR), BP neural network (BPNN), and random forest regression (RF). The research achieved the precise dynamic inversion of SPAD during the key growth period of millet, which was of great significance for the intelligent monitoring of crop growth and the precise application of nitrogen fertilizer.

Key words: millet; SPAD; scale conversion; UAV; satellite remote sensing; collaborative correction model

0 引言

谷子是我国北方干旱、半干旱地区广泛种植的代表性杂粮作物,兼具高产、抗旱、耐病等优势,其生长状态的精准监测对品种选育与产量预测至关重要^[1]。叶片叶绿素相对含量是反映作物光合能力的核心指标,直接关联作物物质能量交换效率与产量品质^[2-3]。及时准确监测其含量对推动精准农业发展意义重大。传统叶片叶绿素相对含量测定方法包括分光光度法^[4]、便携式叶绿素仪测定法^[5]及激光诱导荧光法^[6]等,但这些方法存在固有缺陷:破坏性采样,时空连续性差,且均无法实现大范围动态监测,难以满足规模化种植下谷子生理状态实时诊断的需求。

近年来,遥感技术与无人机技术在作物生长参数估测领域的广泛应用,为快速、无损获取农田作物生长信息提供了新途径。无人机搭载高光谱相机可获取多维度影像,能够进行叶绿素含量反演^[7-9]、叶面积指数^[10-11]、氮元素含量^[12-13]等理化参数的估算。然而,单一无人机遥感平台受续航与覆盖范围限制,难以支持大规模、连续监测的需求^[14-15];卫星遥感虽具备范围广、重访周期短的优势,但其空间分辨率较低,在谷子冠层结构随生育期存在叶片分布、

穗部遮挡等动态变化的情况下,难以捕捉作物细微生长的差异,从而限制了其对 SPAD 值变化的敏感度。因此,仅基于单一无人机或卫星遥感所构建的 SPAD 反演模型难以平衡高精度与大范围的监测需求。为解决这一矛盾,需通过尺度转换技术协同多源遥感数据,整合不同平台优势以突破监测能力的局限。现有研究证明,利用尺度转换方法将无人机遥感数据上推以修正卫星数据后能够有效提高模型反演精度^[16-18]。

鉴于此,本文以河北省保定市顺平县谷子试验地关键生育期谷子为研究对象,同步获取无人机与卫星遥感影像及地面实测数据。首先通过尺度效应评价筛选最优升尺度方法,优先采用点扩散函数法将无人机遥感数据升尺度至卫星尺度,结合均值-方差法对 GF-1 卫星影像数据进行辐射修正,并利用支持向量回归(SVR)构建无人机-卫星多源遥感数据协同校正模型;在此基础上优选光谱特征,引入 4 种算法构建不同生育时期叶绿素相对含量反演模型;最终通过分析修正前后卫星数据模型性能,验证多源遥感数据协同的效益。本研究旨在将多源遥感数据的尺度转换应用至谷子叶片叶绿素相对含量估算,以期为实现高精度、大范围的作物生长参数信息监测和农业生产提供理论支撑。

1 材料与方法

1.1 研究区概况

以河北省保定市顺平县耕耘农机服务专业合作社的谷子试验田(38°46'N,115°08'E)为研究区,其地理位置如图 1a 所示。在 2023 年拔节期(7 月 28 日)、抽穗期(8 月 21 日)、灌浆期(9 月 10 日)和成熟期(9 月 28 日)开展无人机飞行试验。试验选用了在华北地区广泛种植的“冀谷 19”和“冀谷 38”2 个谷子品种,二者分别具有株型紧凑抗倒伏、抗旱适应性强等特性。共设置 6 个 40 m² 小区,每个品种各分配 3 个小区。试验期间,在田间均匀布设 310 个采样点以采集叶绿素相对含量数据,采样点空间分布如图 1b 所示。




图 1 研究区地理位置与采样点空间分布
Fig.1 Geographical location of study area and spatial distribution of sampling points

1.2 数据获取与预处理

1.2.1 实测数据采集测定

采用 SPAD-502 型叶绿素仪(日本美能达公司)对谷子叶片进行地面叶绿素相对含量测定。通过测量叶片在波长 650 nm 和 940 nm 下的透光系数,获取叶绿素的相对含量。在每个样点周围选取 5 株代表性植株,每片叶片均匀进行 3 次重复测量,取平均值作为该样本的 SPAD 值,确保与冠层光谱数据实现空间对应。同时,在采集 SPAD 值时同步记录采样点的经纬度信息。

1.2.2 无人机遥感数据采集与处理

采用 DJI Matrice 600 Pro 型无人机搭载 GaiaSky mini2-VN 推扫式光谱成像系统获取遥感影像数据。无人机飞行与地面同步观测同时进行,选择晴朗无风、光照稳定的天气条件,并安排在正午时段(10:00—14:00)执行飞行任务,以确保太阳高度角较高且光照均匀。利用地面定标白板完成相对辐射校正。根据研究区地形特征设计航线,确保影像完整覆盖研究区域,设定飞行高度为 200 m,目标空间分辨率为 10 cm,为后续与 GF-1 WFO 卫星数据进行尺度转换及协同校正提供高精度参考基准。原始

影像经 SpecView 软件完成镜像变换、黑白帧校准、反射率校正和大气校正处理后,构建出无人机遥感影像数据集。最后,通过软件 ENVI 5.6 分别提取蓝(B)、绿(G)、红(R)和近红外(NIR)波段的反射率。

1.2.3 卫星遥感数据采集与处理

采用 GF-1 WFO 卫星遥感影像,数据来源于中国资源卫星应用中心。影像采集时间与地面观测数据同步,确保了数据的一致性和可靠性。GF-1 WFO 传感器空间分辨率为 16 m,具有覆盖范围广、重访周期短、数据获取成本低等特点,适用于大范围农业监测需求^[19]。尽管亚米级高分辨率影像在空间细节表现上更具优势,但其单景覆盖范围有限,难以实现区域尺度的高频连续观测,且数据采购成本较高,不利于农业应用中的长期、大范围推广^[20]。相比之下,GF-1 WFO 影像在空间分辨率与覆盖范围之间取得了较好平衡,其高频重访能力足以捕捉田块尺度下谷子在不同生育期的光谱特征变化。该数据与无人机高光谱影像之间的分辨率差异显著,也为验证本研究提出的多源数据协同校正与尺度转换方法提供了有利条件。原始影像经软件 ENVI 5.6 完成辐射定标、大气校正、正射校正等预处理后,提取蓝(B)、绿(G)、红(R)和近红外(NIR)波段的反射率,构建卫星遥感影像数据集。

1.3 多源遥感数据协同校正模型的构建

采用点扩散函数法(PSF),将无人机遥感影像升尺度至 16 m 空间分辨率,以实现与 GF-1 卫星遥感数据的空间分辨率一致。其核心原理是构建一种距离相关的加权函数,以中心像素为基准,对影像中各像素位置赋予随距离增加而逐渐衰减的权重,直至趋近于零^[21]。基于这一特性,可通过拟合相应的权重窗口对高分辨率影像实施低通滤波,进而模拟生成与目标传感器空间分辨率相匹配的低分辨率遥感数据。采用影像中所有像素的均值与标准差来表征尺度转换前后的尺度效应;图像转换前后尺度效应越小,表明影像所保留的光谱信息越完整。

随后,利用均值-方差法对 GF-1 卫星影像进行辐射归一化处理,消除卫星与无人机的辐射差异。将待校正影像的像元值线性变换,使其均值和标准差与参考影像一致^[22]。在遥感领域,该方法被广泛应用于多源、多时相遥感影像的辐射一致性校正。本研究以升尺度后的无人机影像作为高精度参考基准,采用均值和标准差来评估尺度效应,采用光谱角映射(SAM)评估辐射校正的效果及光谱形状的保持能力。像元平均值、像元标准差和光谱角映射确定公式分别为

$$\mu = \frac{1}{N} \sum_{i=1}^N p_i \tag{1}$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - \mu)^2} \tag{2}$$

$$\theta = \arccos \frac{\sum_{b=1}^n T_b R_b}{\sqrt{\sum_{b=1}^n T_b^2} \sqrt{\sum_{b=1}^n R_b^2}} \tag{3}$$

式中 N ——图像中像素的总数
 p_i ——第 i 个像素的灰度
 μ ——影像所有像元的平均值,图像转换前后,两者平均值越接近,光谱信息保留越完整
 σ ——影像标准差,图像转换前后,两者标准差越接近,光谱信息保留越完整
 n ——光谱的波段数
 T_b ——待评估影像中像素在第 b 个波段的值
 R_b ——参考影像对应像素在第 b 个波段的值

θ ——光谱角, θ 越小,说明两条光谱形状越相似,匹配度越高

最后,基于升尺度后的无人机遥感数据,通过软件 ENVI 5.6 提取蓝 (B)、绿 (G)、红 (R) 和近红外 (NIR) 波段的反射率。以卫星影像的反射率数据为输入变量,升尺度后的无人机影像的反射率数据为输出变量,采用 SVR 算法构建协同校正模型,以达到建立卫星与无人机反射率的非线性映射,优化卫星数据。在本研究中,采用高斯径向基核函数 (Radial basis function, RBF) 构建非线性映射^[23],以有效处理光谱特征与反射率之间复杂的非线性关系。为评估校正模型的性能并提升其鲁棒性,训练过程中实施了五折交叉验证,在每个折叠中,数据集被划分为 5 个子集,其中 4 个子集用于训练,1 个子集用于测试。此过程重复 5 次,确保每个子集都用作测试集一次,在有限样本条件下可在保证训练数据量的同时,有效避免过拟合,提供更为稳定的模型性能评估结果。本文的技术路线如图 2 所示。




图 2 研究技术流程图
Fig. 2 Research technology flowchart

1.4 光谱特征提取与筛选

选取 4 个光谱波段的直接特征和 8 个基于植被指数的衍生特征,共 12 种光谱指数用于谷子叶绿素相对含量的反演。具体包括:蓝 (B)、绿 (G)、红 (R)、近红外 (NIR) 波段、归一化植被指数 (NDVI)^[24]、绿色归一化植被指数 (GNDVI)^[25]、土壤调节植被指数 (SAVI)^[26]、比值植被指数 (RVI)^[27]、绿度指数 (GI)^[28]、增强型植被指数

(EVI)^[29]、红外植被指数 (IPVI)^[30] 以及修正三角植被指数 (MTVI)^[31]。

采用皮尔逊相关性分析和 XG-Boost 特征重要性选择二者结合进行特征子集筛选。计算谷子各生长时期下所有光谱特征与叶绿素相对含量的相关系数,筛选出具有较强相关性的特征。利用 XG-Boost 特征重要性选择对具有相关性的特征进行重要性排序,保留反演叶绿素相对含量贡献最大的特

征,构建谷子各生育期的最优光谱特征集。

1.5 叶绿素相对含量反演模型构建

基于各生育期的最优光谱特征集,以叶绿素相对含量为反演目标,构建长短期记忆网络 (Long short-term memory, LSTM) 反演模型。LSTM 能够有效捕捉作物在不同生育期的时序光谱特征,从而动态建模生长过程,有助于提升叶绿素相对含量反演精度。然而,LSTM 模型的超参数设置复杂,其取值直接影响模型性能与收敛效率。为充分发挥模型潜力,避免陷入局部最优或过拟合,需借助优化算法实现超参数自动寻优。为此,本研究引入一种改进灰狼优化算法 (Improved grey wolf optimization algorithm, IGWO),并结合非线性收敛因子 (Nonlinear convergence factor, NCF)^[32]来优化其搜索行为。该因子直接控制灰狼的搜索范围,其值在迭代初期缓慢减小以维持较强的全局探索能力,避免早熟;在迭代后期加速减小以增强局部精细开发能力,提高收敛精度,从而实现动态、智能地平衡全局搜索与局部搜索过程,使算法在前期广泛探索参数空间,在后期精准开发潜在最优区域,从而更有效地寻找到 LSTM 模型的最佳超参数组合。

1.6 模型训练与评估

数据集按照比例 7:1:2 随机划分为训练集、验证集和测试集。模型训练在配备英特尔 i9-14900K 中央处理器、NVIDIA RTX 4090 图形处理器及 128 GB 内存的硬件平台上进行。深度学习框架采用 PyTorch,并结合 CUDA 12.6 并行计算架构以支持高效训练。模型性能评估采用均方根误差 (Root mean square error, RMSE) 和决定系数 (Coefficient of determination, R^2) 作为评价指标。其中, RMSE 用于衡量预测值与真实值之间的平均偏差,其值越小表明模型预测精度越高; R^2 用于评估模型对目标变量的拟合优度,取值越接近 1,表示模型解释能力越强。

2 结果与分析

2.1 基于 PSF 的尺度转换效果评估

为验证各生育期遥感影像在尺度转换后的数据有效性,采用关键生育期各波段像元灰度均值与标准差进行定量评估,并系统比较了最邻近法 (Nearest)、双线性内插法 (Bilinear) 和立方卷积内插法 (Cubic) 3 种重采样升尺度方法的转换效果,结果如图 3a 所示。

在蓝色、绿色和红色波段中,原始无人机影像的像元均值约为 0.056,标准差约为 0.013;双线性内插法和点扩散函数法转换后的影像像元均值分别为

0.07、0.043,标准差分别为 0.011、0.013;立方卷积插值法和最邻近法转换后的像元均值分别为 0.096、0.092,标准差分别为 0.008、0.041。




图 3 基于平均值、标准差的尺度效应与光谱角映射 (SAM) 评估对比

Fig.3 Comparison of scale effect and spectral angle mapping (SAM) evaluation based on mean and standard deviation

在近红外波段中,原始无人机影像的像元均值约为 0.029,标准差约为 0.01;双线性内插法和点扩散函数法转换后的影像像元均值分别为 0.092、0.057,标准差分别为 0.017、0.012;立方卷积插值法和最邻近法转换后的像元均值分别为 0.103、0.068,标准差分别为 0.053、0.018。

整体来看,点扩散函数法转换的影像,其像元均值与标准差都与原始无人机影像最为接近,结果表明能够在升尺度过程中较好地保存原始影像的光谱信息。因此,采用点扩散函数法对无人机遥感影像进行尺度转换更加合适。

2.2 基于 SVR 的多源遥感数据协同校正模型效果评估

为验证均值-方差法在多源遥感数据辐射校正中的效果,首先采用光谱角映射 (SAM) 评估关键生育期内校正后光谱形状的保持能力。如图 3b 所示,拔节期、抽穗期、灌浆期与成熟期的光谱角映射值均低于 0.1°,分别为 0.074°、0.062°、0.091°和 0.086°,表明经校正后的影像在光谱特征保持方面表现优异,有效支持后续定量反演分析。

进一步,为系统评估所构建无人机-卫星协同校正模型的性能,在 4 个主要生育期开展了多波段回归精度验证,并以偏最小二乘法 (Partial least squares regression, PLSR)、随机森林 (Random forest, RF)、BP 神经网络 (Back propagation neural network, BPNN) 作为对比模型 (表 1)。结果显示,SVR 在关键生育期的 B、G、R 和 NIR 波段的 R^2 分别为 0.920、0.961、0.963、0.900; PLSR 的 R^2 分别为 0.873、0.855、0.851、0.826; RF 的 R^2 分别为 0.900、0.860、0.870、0.840; BPNN 的 R^2 分别为 0.910、0.900、0.930、0.870。结果表明,基于 SVR 构建的校正模型精度显著优于其他模型,能够有效校正关键生育期卫星

4 个波段的反射率。

表 1 4 种机器学习算法构建的校正模型性能

Tab.1 Performance of calibration models built by four machine learning algorithms

波段	SVR		PLSR		RF		BPNN	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
B	0.920	0.097	0.873	0.159	0.900	0.162	0.910	0.133
G	0.961	0.081	0.855	0.272	0.860	0.211	0.900	0.153
R	0.963	0.072	0.851	0.301	0.870	0.260	0.930	0.109
NIR	0.900	0.140	0.826	0.177	0.840	0.147	0.870	0.204

2.3 光谱指数筛选与最优特征集确立

为系统评估光谱指数与叶绿素相对含量 (SPAD) 之间的关联性,基于 Pearson 相关系数对 12 种光谱指数在关键生育期进行了相关性分析 (图 4)。结果表明,不同生育阶段中与 SPAD 显著相关的光谱指数数量及其相关强度存在明显差异。在拔节期,共有 8 个指数与 SPAD 呈显著相关 ($P < 0.05$),其中 EVI 和 GI 表现出较强的正相关性,相关系数分别为 0.797 和 0.813;B 与 R 则呈现较强的负相关性,相关系数分别为 -0.780 和 -0.792 。至抽穗期,显著相关的指数增至 9 个,GNDVI、NDVI 和 EVI 显示强正相关,B 和 R 仍为强负相关,相关

系数分别为 0.876、0.836、0.857、 -0.872 和 -0.823 。灌浆期显著相关的特征减少至 8 个,其中 GNDVI 保持较高的正相关性,B 和 R 持续表现为强负相关,相关系数分别为 0.713、 -0.725 和 -0.728 。成熟期显著相关的特征进一步降至 7 个,且整体相关强度有所减弱,RVI 和 NDVI 为主要正相关指数,B 为唯一显著负相关变量,相关系数分别为 0.591、0.578 和 -0.341 。基于上述分析,初步筛选出各生育期可用于 SPAD 反演的候选光谱指数。

为进一步获取兼具代表性与建模效率的特征子集,本研究采用结合特征重要性评估与模型性能验证的双重筛选策略 (图 5)。首先,利用 XG-Boost 算法计算各生育期内候选光谱指数的特征重要性得分,并按降序排列。结果显示:拔节期特征重要性排序依次为 B、GNDVI、NDVI、G、SAVI、R、EVI、GI;抽穗期为 G、NDVI、B、SAVI、GNDVI、R、EVI、IPVI、GI;灌浆期为 B、G、IPVI、R、EVI、NDVI、GNDVI、RVI;成熟期为 NDVI、G、GNDVI、EVI、B、RVI、IPVI。随后通过特征数量对比实验发现 (图 6),当输入特征数为 5 时,模型预测精度达到最优,即拔节期 $R^2 = 0.712$, RMSE 为 0.281;抽穗期 $R^2 = 0.814$, RMSE 为 0.222;灌浆期 $R^2 = 0.827$, RMSE 为 0.253;成熟期




图 4 不同生育时期光谱指数与谷子 SPAD 值的相关系数

Fig.4 Correlation coefficients between spectral indices and chlorophyll SPAD values at different growth periods




图 5 基于 XG - Boost 算法的特征重要性排序结果

Fig. 5 Feature importance ranking based on XG - Boost algorithm




图 6 最优光谱指数组合

Fig. 6 Optimal combination of spectral indices

$R^2 = 0.850$, RMSE 为 0.228。

综合分析表明,选取各生育期重要性排名前 5 的特征可有效捕捉光谱信息与叶绿素相对含量之间的非线性关系,同时降低过拟合风险。最终确定各时期最优特征组合,即拔节期为 B、GNDVI、NDVI、G、SAVI;抽穗期为 G、NDVI、B、SAVI、GNDVI;灌浆期为 B、G、IPVI、R、EVI;成熟期为 NDVI、G、GNDVI、EVI、B。由此构建了适用于谷子 SPAD 反演的最优光谱特征数据集。

2.4 基于 IGWO - LSTM 模型的叶绿素相对含量反演结果评估

2.4.1 消融实验

为了评估 IGWO 优化策略的有效性与可行性,设计了多组消融实验,采用不同建模方案进行对比分析。实验方案包括:仅使用 LSTM 构建的 SPAD 反演模型;采用 GWO 优化的 LSTM 构建反演模型;采用 IGWO 优化的 LSTM 构建反演模型。消融实验结果如表 2 所示。从第 3 组结果可见,IGWO -

LSTM 模型表现出最小的反演误差和最优的拟合性能,其 RMSE 为 0.125, R^2 达到 0.957。相较于 GWO - LSTM 模型,IGWO - LSTM 的误差降低 37.19%,拟合优度提升 5.75%;相较于基础 LSTM 模型,误差降低 42.13%,拟合优度提高 8.63%。上述结果表明,在 LSTM 模型训练过程中引入 GWO 算法有助于有效寻优超参数;而进一步采用引入非线性收敛因子的 IGWO 算法,能够更好地平衡全局搜索与局部搜索能力,显著提升超参数优化效率与模型性能。

表 2 消融实验结果

Tab. 2 Ablation test results

试验组	LSTM	GWO	IGWO	R^2	RMSE
1	✓	×	×	0.881	0.216
2	✓	✓	×	0.905	0.199
3	✓	×	✓	0.957	0.125

注:表中“✓”表示同一实验组建模方案中采用的算法,“×”表示同一实验组建模方案中未采用的算法。

2.4.2 对比实验

为评估基于无人机-卫星遥感数据校正的 IGWO - LSTM 模型在 SPAD 反演中的性能,将其结果与使用原始卫星数据的 IGWO - LSTM 模型对比,并选取 PLSR、BPNN 和 RF 等主流模型进行多模型比较(图 7)。

4 种模型中,IGWO - LSTM 表现出最强的鲁棒性和估测精度。基于校正后的卫星光谱数据 IGWO - LSTM 模型在 4 个生育期的 R^2 均保持在 0.9 以上,其中灌浆期达到最高,为 0.985, RMSE 均低于 0.2。关键生育期的平均 R^2 以及 RMSE 显著优于对比模型,其中 PLSR 的 R^2 和 RMSE 分别为 0.845、0.312; BPNN 的 R^2 和 RMSE 分别为 0.819、0.336; RF 的 R^2




图 7 PLSR、BPNN、RF 与 IGWO-LSTM 模型的谷子 SPAD 值反演精度对比

Fig. 7 Comparison of inversion accuracy of millet SPAD values by PLSR, BPNN, RF and IGWO-LSTM models

和 RMSE 分别为 0.817、0.309。

不同数据源的对比结果显示,校正后的卫星光谱数据显著提升了 4 种模型在谷子关键生育期 SPAD 反演中的精度。其中,IGWO-LSTM 表现最优,相较于基于未校正卫星数据的模型,拔节期、抽穗期、灌浆期和成熟期的 R^2 分别提高 14.00%、22.51%、14.47% 和 16.69%, RMSE 分别降低 42.86%、58.43%、48.10% 和 39.90%。结果表明,使用校正后的数据可在保持监测广度的同时,显著提升反演精度。

综上所述,基于无人机与卫星遥感数据协同校正的 IGWO-LSTM 模型可实现谷子关键生育期 SPAD 的高精度、大范围估算,为作物生理参数的遥感反演提供了可靠的技术支持。

3 讨论

3.1 多源数据协同校正模型优势

本研究提出一种基于无人机遥感数据对多源卫星遥感数据进行协同校正的方法。针对谷子冠层在不同生育期所表现出的叶片空间分布变化及穗部遮挡效应,在处理此类具有显著非均质性与空间异质性的尺度转换问题时选用合适的尺度转换方法对准评估 SPAD 值具有重要意义^[33]。点扩散函数法相较于传统重采样方法能够更有效地实现遥感数据的尺度上推,不仅保留了原始影像的大部分信息,且具有较高的光谱形状保真度, SAM 为 0.062 ~ 0.091,为 SPAD 反演模型的构建提供了高质量的无

人机遥感数据基础,这与前人的研究结果一致^[34]。进一步地,采用支持向量回归(SVR)构建的辐射校正模型在关键生育期各波段均表现出最优精度, R^2 最高达 0.963,可有效校正卫星 4 个波段在关键生育期的反射率数据,为实现谷子 SPAD 值的大范围高精度反演提供了可靠的技术支撑。

3.2 反演模型性能评估

基于协同校正后的卫星光谱数据,构建了谷子各关键生育期的 SPAD 值反演模型。结果表明,IGWO-LSTM 模型的反演精度显著优于传统机器学习模型。通过消融实验对 LSTM 与 IGWO 算法的互补效应进行分析,发现引入具有非线性收敛因子的 IGWO 算法能够有效优化 LSTM 的超参数寻优过程,增强其全局与局部搜索能力,从而提高反演精度和模型稳定性。同时,本研究在相同数据基础上与 PLSR、BPNN 和 RF 等算法进行对比实验,结果显示 IGWO-LSTM 模型在各关键生育期均表现最优,其 R^2 较对比模型提高 9% ~ 25%, RMSE 降低 53% ~ 71%,说明 IGWO-LSTM 模型能够更好地捕捉 SPAD 值与光谱特征之间复杂的非线性关系。

3.3 限制与未来工作

本研究尚存在一定的局限性。首先,建模所使用的样本数据来源于研究区的特定品种,覆盖拔节期至成熟期 4 个关键生育期,导致光谱特征受到特定时空分布条件的限制,进而影响其不同土壤背景与气候区的普适性。其次,本研究仅基于敏感波段及植被指数组数据构建模型,在一定程度上反映

了 SPAD 的变化特征,会限制 SPAD 反演模型的鲁棒性。在未来的研究中应致力于拓展样本采集范围,针对性采集不同品种、气候及土壤类型下的谷子样本;结合纹理特征、冠层结构参数等多维特征信息并融合关键生育周期的地面实测数据,以进一步提升反演模型的适用性和泛化能力。

4 结论

- (1)本研究融合无人机与卫星多源遥感数据,提出基于改进灰狼优化算法(IGWO)优化长短期记忆神经网络(LSTM)的谷子叶绿素相对含量反演方法。
- (2)点扩散函数法在无人机影像尺度转换中优势显著,转换后影像的像元均值、标准差与原始数据最为接近,支持向量回归(SVR)构建的多源数据校正模型,在多波段拟合精度上表现突出,精度最高可

- 达 $R^2 = 0.963$,显著提升了关键生育期内卫星影像 4 个波段的反射率校正效果,为实现无人机-卫星遥感数据的高精度协同提供了一种可靠的校正机制。
- (3)引入非线性收敛因子的 IGWO 算法,有效平衡了全局与局部的搜索能力,经其优化的 IGWO-LSTM 模型,在谷子叶绿素相对含量反演中展现出卓越的鲁棒性与预测精度,RMSE 为 0.125, $R^2 = 0.957$,显著优于传统模型,为 SPAD 高精度估算提供了可靠工具。
- (4)基于多源数据协同校正与 IGWO-LSTM 算法的融合框架,实现了谷子关键生育期叶绿素相对含量的高精度、大范围估算,抽穗期反演性能提升尤为显著,相较于基于未校正卫星数据的模型, R^2 提升 22.51%,RMSE 降低 58.43%。为谷子生长智能监测和农田精准管理提供了一种可靠的技术手段。

参 考 文 献

[1] 程雪,付颖,柴晓娇,等. 谷子 LHC 基因家族鉴定及非生物胁迫表达分析[J]. 生物技术通报,2025,41(8):102-114. CHENG Xue, FU Ying, CHAI Xiaojiao, et al. Identification of LHC gene family in setaria italica and expression analysis under abiotic stresses[J]. Biotechnology Bulletin, 2025,41(8):102-114. (in Chinese)

[2] 吴尘萱,栗君谊,韩亚芬,等. 面向植物合成生物学的植物工厂生产关键技术与装备研究进展及应用展望[J]. 农业机械学报,2025,56(7):300-315. WU Chenxuan, LI Junyi, HAN Yafen, et al. Research progress and application prospects of key technologies and equipment for plant factory production in plant synthetic biology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7):300-315. (in Chinese)

[3] FENG Z H, GUAN H W, YANG T C, et al. Estimating the canopy chlorophyll content of winter wheat under nitrogen deficiency and powdery mildew stress using machine learning [J]. Comput. Electron. Agric., 2023, 211: 107989.

[4] 朱盛凡,白驹驰,金忠煜,等. 基于改进 PIOSL 辐射传输模型的水稻叶绿素含量估测研究[J]. 农业机械学报,2025, 56(9):576-84,637. ZHU Shengfan, BAI Juchi, JIN Zhongyu, et al. Estimation of chlorophyll content in rice based on improved PIOSL radiative transfer model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(9):576-84,637. (in Chinese)

[5] 苗世龙,李仙岳,史海滨,等. 基于机器学习的玉米 SPAD 值影像分期反演与水氮优化利用研究[J]. 农业机械学报, 2025,56(9):536-546. MIAO Shilong, LI Xian Yue, SHI Haibin, et al. Staging inversion of maize SPAD values and optimal utilization of water and nitrogen based on machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(9):536-546. (in Chinese)

[6] 安学兰,聂志刚,李广,等. 基于机器学习的不同生育期下玉米叶片叶绿素含量反演研究[J]. 软件导刊,2025,24(5): 62-69. AN Xuelan, NIE Zhigang, LI Guang, et al. Research on the inversion of chlorophyll content in maize leaves at different growth stages based on machine learning[J]. Software Guide, 2025,24(5):62-69. (in Chinese)

[7] ZHAI W G, LI C C, FEI S P, et al. CatBoost algorithm for estimating maize above-ground biomass using unmanned aerial vehicle-based multi-source sensor data and SPAD values[J]. Comput. Electron. Agric., 2023, 214: 108306.

[8] 祝清霞,朱艳秋,王爱臣,等. 基于无人机多光谱植被指数与纹理特征的水稻叶绿素含量反演[J]. 农业机械学报, 2024,55(12):287-293. ZHU Qingzhen, ZHU Yanqiu, WANG Aichen, et al. Accurate inversion of rice chlorophyll content by integrating multispectral and texture features derived from UAV multispectral imagery [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):287-293. (in Chinese)

[9] LIU Q S, CHEN F, CUI N B, et al. Inversion of citrus SPAD value and leaf water content by combining feature selection and ensemble learning algorithm using UAV remote sensing images[J]. Agric. Water Manag., 2025, 314: 109524.

[10] TIAN Y J, JIANG Y F, ZENG M, et al. Inversion of cotton leaf area index under verticillium wilt stress from UAV multispectral images: deep learning-based vs. classical-based algorithms [J]. Industrial Crops and Products, 2025, 233:

121345.

- [11] LIU Q, HU X L, ZHANG Y Q, et al. Improving maize water stress diagnosis accuracy by integrating multimodal UAVs data and leaf area index inversion model [J]. *Agric. Water Manag.*, 2025, 312: 109407.
- [12] 范耀冰, 吴尚蓉, 匡炜, 等. 基于无人机高光谱影像的稻谷氮含量估算研究[J]. *农业机械学报*, 2025, 56(1): 332 – 343, 423.
- FAN Yaobing, WU Shangrong, KUANG Wei, et al. Estimation of nitrogen content in rice grains based on UAV hyperspectral imagery[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(1): 332 – 343, 423. (in Chinese)
- [13] XIAO C, ZHANG F C, MÄKELÄ P S, et al. An unmanned aerial vehicle-based cotton nitrogen nutrition index estimation model utilizing feature selection and machine learning[J]. *Comput. Electron. Agric.*, 2025, 238: 110798.
- [14] MÉLÉDER V, SAVELLI R, BARNETT A, et al. Mapping the intertidal microphytobenthos gross primary production part I: coupling multispectral remote sensing and physical modeling[J]. *Frontiers in Marine Science*, 2020, 7: 520.
- [15] 张智韬, 刘彦甫, 胡笑涛, 等. 多源遥感数据驱动的农业水利信息感知与应用研究进展[J]. *农业机械学报*, 2025, 56(8): 1 – 20.
- ZHANG Zhitao, LIU Yanfu, HU Xiaotao, et al. Advancements in perception and application of agricultural water resources information driven by multi-source remote sensing data[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(8): 1 – 20. (in Chinese)
- [16] 马仪, 黄组桂, 贾江栋, 等. 基于无人机-卫星遥感升尺度的土壤水分监测模型研究[J]. *农业机械学报*, 2023, 54(6): 307 – 318.
- MA Yi, HUANG Zugui, JIA Jiangdong, et al. Soil moisture monitoring model based on UAV – Satellite remote sensing scale-up[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(6): 307 – 318. (in Chinese)
- [17] 董雨昕, 韩文霆, 崔欣, 等. 基于无人机与 Sentinel – 2A 遥感数据协同的裸土期土壤含盐量反演[J]. *农业机械学报*, 2025, 56(6): 434 – 445.
- DONG Yuxin, HAN Wenting, CUI Xin, et al. Soil salinity inversion during bare soil period based on collaboration of UAV and Sentinel – 2A remote sensing data[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(6): 434 – 445. (in Chinese)
- [18] 王鹏新, 刘郊, 李俐, 等. 基于点扩散函数的条件植被温度指数降尺度转换方法[J]. *农业机械学报*, 2017, 48(12): 165 – 173.
- WANG Pengxin, LIU Jiao, LI Li, et al. Downscaling transformation method for vegetation temperature condition index based on point spread function[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2017, 48(12): 165 – 173. (in Chinese)
- [19] JIANG H Y, KUN J, WANG, Q, et al. Angular effect correction for improved LAI and FVC retrieval using GF – 1 wide field view data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 1 – 14.
- [20] CUI Y, LIU S H, LI X G, et al. Estimating maize yield in the black soil region of northeast China using land surface data assimilation: integrating a crop model and remote sensing[J]. *Front Plant Sci.*, 2022, 13: 915109.
- [21] NAN Y J, HUANG X J, GUO Y J. 3-D millimeter-wave helical imaging[J]. *IEEE Trans. Microwave Theory Tech.*, 2022, 70(4): 2499 – 2511.
- [22] 李熙, 布布莉·叶尔勒克, 郑建川, 等. 基于夜光遥感的深圳西涌暗夜保护社区光污染控制有效性评估[J]. *热带地理*, 2025, 45(8): 1373 – 1388.
- LI Xi, BUBULI Yeerleke, ZHENG Jianchuan, et al. Evaluation of the effectiveness of light pollution control in Shenzhen Xichong dark sky preserve based on nighttime light remote sensing[J]. *Tropical Geography*, 2025, 45(8): 1373 – 1388. (in Chinese)
- [23] CHEN J C, FAN F C, WEI C F, et al. Decoding driving states based on normalized mutual information features and hyperparameter self-optimized Gaussian kernel-based radial basis function extreme learning machine[J]. *Chaos Solitons & Fractals*, 2025, 199: 116751.
- [24] CARLSON T N, RIPLEY D A. On the relation between NDVI, fractional vegetation cover, and leaf area index [J]. *Remote Sens. Environ.*, 1997, 62(3): 241 – 252.
- [25] GITELSON A A, MERZLYAK M N. Remote sensing of chlorophyll concentration in higher plant leaves [J]. *Adv. Space Res.*, 1998, 22(5): 689 – 692.
- [26] ROUJEAN J L, BREON F M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements [J]. *Remote Sens. Environ.*, 1995, 51(3): 375 – 384.
- [27] GONENC A, OZERDEM M S. Comparison of NDVI and RVI vegetation indices using satellite images [C] // 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics). *IEEE*, 2019.
- [28] WU L B, HOLTKAMP F, WAIRICH A, et al. Potassium ion channel gene OsAKT1 affects iron translocation in rice plants exposed to iron toxicity[J]. *Front Plant Sci.*, 2019, 10: 579.
- [29] HUETE A, KAMEL D, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. *Remote Sens. Environ.*, 2002, 83(1 – 2): 195 – 213.

[30] TIAN X C, JIA X Y, DA Y Z, et al. Evaluating the sensitivity of vegetation indices to leaf area index variability at individual tree level using multispectral drone acquisitions[J]. *Agric. For Meteorol.*, 2025, 364: 110441.

[31] GAO S, RUN Z, YAN K, et al. Evaluating the saturation effect of vegetation indices in forests using 3D radiative transfer simulations and satellite observations[J]. *Remote Sens Environ*, 2023, 295: 113665.

[32] ATTO A M, GALICHET S, PASTOR D, et al. On joint parameterizations of linear and nonlinear functionals in neural networks[J]. *Neural Netw.*, 2023, 160: 12–21.

[33] 张智韬, 陈钦达, 黄小鱼, 等. 基于加权算法的空-天遥感升尺度土壤含盐量监测模型[J]. *农业机械学报*, 2022, 53(9): 226–238, 251.

ZHANG Zhitao, CHEN Qinda, HUANG Xiaoyu, et al. UAV – satellite remote sensing scale-up monitoring model of soil salinity based on dominant class variability-weighted method [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 226–238, 251. (in Chinese)

[34] 王鹏, 严昂, 张弓. 考虑点扩散函数效应的光谱遥感图像超分辨率制图[J]. *信号处理*, 2024, 40(3): 599–608.

WANG Peng, YAN Ang, ZHANG Gong. Considering point spread function effect for spectral remote sensing image super-resolution mapping[J]. *Journal of Signal Processing*, 2024, 40(3): 599–608. (in Chinese)

~~~~~

(上接第 168 页)

[21] LACOTTE V, NGUYEN T, SEMPERE J D, et al. Pesticide-free robotic control of aphids as crop pests[J]. *AgriEngineering*, 2022, 4(4): 903–921.

[22] JIANG T, ZHONG Y. ODverse33: is the new YOLO version always better? A multi domain benchmark from YOLO v5 to v11 [A]. *arXiv Preprint*, arXiv: 2502. 14314, 2025.

[23] XU W, THOMASSON J A, SU Q, et al. A segmentation algorithm incorporating superpixel block and holistically nested edge for sugarcane aphids images under natural light conditions[J]. *Biosystems Engineering*, 2022, 216: 241–255.

[24] XU W, XU T, ALEX THOMASSON J, et al. A lightweight SSV2 – YOLO based model for detection of sugarcane aphids in unstructured natural environments[J]. *Computers and Electronics in Agriculture*, 2023, 211: 107961.

[25] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[J]. *Journal of Real-Time Image Processing*, 2024, 21(3): 62.

[26] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[J]. *arXiv Preprint*, arXiv: 1109. 01155, 2020.

[27] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. *arXiv Preprint*, arXiv: 1612. 03144, 2017.

[28] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[J]. *arXiv Preprint*, arXiv: 1911. 09070, 2019.

[29] TONG Z, CHEN Y, XU Z, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism[J]. *arXiv Preprint*, arXiv: 2301. 10051, 2023.

[30] WANG Z, JIN L, WANG S, et al. Apple stem/calyx real-time recognition using YOLO v5 algorithm for fruit automatic loading system[J]. *Postharvest Biology and Technology*, 2022, 185: 111808.

[31] 郑俊健, 兰玉彬, 熊万杰, 等. 基于 YOLOv5s 改进模型的小白菜虫害识别方法[J]. *农业工程学报*, 2024, 40(13): 124–133.

ZHENG Junjian, LAN Yubin, XIONG Wanjie, et al. Method for identification of Pak choi pests and diseases based on improved YOLOv5s[J]. *Transactions of the CSAE*, 2024, 40(13): 124–133. (in Chinese)