

基于半经验半机理建模的冬小麦 LAI 反演及长势评估

刘昕哲¹, 武璐¹, 陈李金², 马宇帆¹, 李涛¹, 吴婷婷^{1*}

(1. 西北农林科技大学机械与电子工程学院, 杨凌 712100; 2. 西北农林科技大学农学院, 杨凌 712100)

摘要: 为了提高无人机遥感对冬小麦叶面积指数 (leaf area index, LAI) 反演模型的精度与泛化能力, 该研究利用无人机搭载多光谱相机获取不同氮素处理和不同复种方式的冬小麦生长实测数据, 结合 PROSAIL 辐射传输模型生成包含机理信息的模拟数据, 基于不同组合方式建立了 5 种 LAI 反演混合数据集, 结合多种机器学习方法, 以期构建经验与机理相结合的 LAI 高精度反演模型。由于 LAI 反演受 NIR 波段反射率影响大, 该研究筛选 7 种与 NIR 波段相关的植被指数提取冬小麦光谱特征, 构建与混合数据集 LAI 的相关系数矩阵, 进一步探究不同光谱特征对冬小麦 LAI 的影响程度。在此基础上, 采用具有代表性和普适性的 4 种机器学习方法, 即贝叶斯岭回归模型、线性回归模型、弹性网络模型和支持向量回归模型, 构建不同冬小麦 LAI 反演模型, 用以评估基于半经验半机理数据反演冬小麦 LAI 的可行性, 进一步探索其对不同氮素水平和复种方式的冬小麦长势评估能力。结果表明: 1) 筛选的与 NIR 波段相关的植被指数与冬小麦 LAI 之间存在较强的相关性, 其中归一化差异植被指数、增强植被指数、归一化差异红边指数、比值植被指数、红边叶绿素植被指数、土壤调节植被指数与 LAI 呈正相关, 结构不敏感色素植被指数与 LAI 呈负相关; 2) 辐射传输模型中体现了冬小麦 LAI 影响太阳光线传播的机理, 结果表明, 与实测数据混合建立的模型, 具有较强的鲁棒性和泛化能力。相比于其他 3 种模型, 支持向量回归模型在各种数据组合下均取得了较好的 LAI 预测性能, 在 C1、C2、C3、C4 这 4 种训练-测试组合的训练集中 R^2 依次为 0.86、0.87、0.88、0.91, RMSE 依次为 0.47、0.45、0.45、0.41; 在测试集的 R^2 依次为 0.85、0.19、0.89、0.87, RMSE 依次为 0.45、1.31、0.49、0.50; 3) 使用支持向量机生成试验区 LAI 反演图, 对 4 种氮素水平和 2 种复种方式的冬小麦长势评估, 结果表明, 适当的施加氮素处理能提高冬小麦 LAI 值, 麦-豆复种方式下的冬小麦 LAI 值普遍高于麦-玉复种的 LAI 值。该研究为冬小麦 LAI 的反演提供了一种有效的方法, 并为高效评估冬小麦长势研究提供了参考。

关键词: 无人机; 遥感; 辐射传输模型; 植被指数; LAI 反演; 机器学习

doi: 10.11975/j.issn.1002-6819.202309071

中图分类号: S123

文献标志码: A

文章编号: 1002-6819(2024)-01-0170-09

刘昕哲, 武璐, 陈李金, 等. 基于半经验半机理建模的冬小麦 LAI 反演及长势评估[J]. 农业工程学报, 2024, 40(1): 170-178. doi: 10.11975/j.issn.1002-6819.202309071 <http://www.tcsae.org>

LIU Xinzhe, WU Lu, CHEN Lijin, et al. LAI inversion and growth evaluation of wheat using empirical-mechanistic modeling[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(1): 170-178. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202309071 <http://www.tcsae.org>

0 引言

叶面积指数 (leaf area index, LAI) 是反映植被冠层结构和功能的关键参数, 它被广泛用于生物量估算和作物长势评估^[1-3]。准确获取作物 LAI 对于实施精准农业管理和提高作物产量具有重要意义^[4-6], 传统的 LAI 测量方法主要依赖手工采样和田间手持式测量仪器^[7-10], 手工采样操作繁琐耗时, 且会破坏叶片的完整性^[11-12]; 手持式测量仪通过测量冠层辐射衰减程度来间接推算 LAI^[13-15]。这些方法普遍存在采样区域不连续和采样速度慢等特点, 难以满足日益增长的无损、高通量检测需求^[16-20]。

收稿日期: 2023-09-09 修订日期: 2023-12-09

基金项目: 国家重点研发计划国际合作重点专项中法联合实验室项目 (2022YFE0116200)

作者简介: 刘昕哲, 研究方向为无人机田间智慧表型获取与分析。

Email: 2021051040@nwafu.edu.cn

*通信作者: 吴婷婷, 博士, 副教授, 研究方向为农情信息智能感知。

Email: tt_wu@nwafu.edu.cn

遥感技术为 LAI 的高通量反演提供了有效途径, 目前发展了多种平台和传感器, 如卫星遥感、航空遥感、地基遥感等。无人机 (unmanned aerial vehicle, UAV) 作为一种新型遥感平台, 具备高灵活性、低成本、高分辨率和高重复性等优点, 逐渐成为 LAI 反演的重要手段^[21-24]。无人机反演 LAI 的方法主要有两类: 基于经验统计模型的方法和基于物理机理模型的方法。LI 等^[25] 基于无人机数字图像获得的颜色和纹理信息估算水稻 LAI, WITTSTRUCK 等^[26] 基于无人机 RGB 数据和卷积神经网络估算冬小麦 LAI, 这类通过建立植被指数 (vegetation index, VI) 与 LAI 的经验关系进行反演的方法, 简单易行, 但易受到地区、季节、作物类型等因素的影响, 缺乏普适性和稳定性^[27-28]。GIORGIO 等^[29] 使用无人机获取多光谱图像和 PROSAIL 模型以相对较高的精度估计大麻 LAI 性状, 这类通过建立植被冠层光谱反射率与 LAI 之间的物理关系进行反演的方法, 具有更强的理论基础和适应性, 但需要考虑更多的影响因素和参数, 计算复杂度高^[30]。

由于大田试验环境复杂多变, 直接基于试验数据建

立机器学习回归模型, 会使得模型学习到更多的噪声, 造成泛化能力差。辐射传输模型 (radiative transfer model, RTM) 是定量遥感研究中的重要机理模型之一, RTM 通过模拟植被冠层内不同波长下太阳辐射的多次散射和吸收过程, 从而得到冠层的光谱反射率^[31-33]。基于 RTM 考虑了植被冠层结构和生物物理特性对光谱反射率影响的特点, 可以将 LAI 等植被参数作为 RTM 的输入, 将光谱反射率作为模型响应输出, 建立光谱反射率-LAI 机理约束条件, 与大田试验数据或方法相结合进行 LAI 反演^[34], 应当可以有效提高反演的精度和可靠性。

本文以陕西省杨凌农业高新技术产业示范区曹新庄实验基地为研究区域, 通过无人机获取田间试验数据, 结合辐射传输模型的约束条件, 构建半经验半机理的冬小麦 LAI 反演模型, 主要探索以下三方面内容: 1) (构建混合数据集泛化能力) 获取高分辨率的试验田冬小麦冠层光谱反射率数据并同步采集地面 LAI 数据作为真值。利用辐射传输模型生成不同 LAI 梯度的模拟数据集, 与试验数据构成混合数据集, 提高模型的鲁棒性; 2) (机器学习模型的选取能否提高反演精度) 采用多种机器学习方法, 对不同组合的数据集进行训练并测试 LAI 反演模型; 3) 基于反演的 LAI 模型对冬小麦长势的评估影响, 分析不同施氮量和复种方式对冬小麦 LAI 的影响, 探讨不同施氮量和复种方式对冬小麦长势的影响。

1 材料与方法

1.1 试验区域

本试验研究区位于陕西省杨凌农业高新技术产业示范区曹新庄实验基地 ($34^{\circ}17'27.05''N$, $108^{\circ}4'31.59''E$), 海拔 $435\sim563$ m、年降水量 $635.1\sim663.9$ mm, 年平均气温 12.9°C , 如图 1 所示。试验区为关中平原腹地, 是典型的西北半湿润易旱区, 土壤类型为壤土, 表层 $0\sim20$ cm 土壤理化性质如下: 有机质: 12.23 g/kg , 全氮: 1.02 g/kg^2 , 速效氮: 94.11 mg/kg , 速效磷: 35.59 mg/kg , 速效钾: 120.15 mg/kg , pH 值 8.1, 土壤容重: 1.22 g/cm^3 。为探究 135 、 180 、 $225\text{ kg}/\text{hm}^2$ 不同等级氮素处理, 冬小麦-玉米复种、冬小麦-大豆复种方式对冬小麦 LAI 的影响, 试验区共划分为 60 个试验小区 (3 个重复 \times 3 种氮素处理 \times 3 种施肥方式 \times 2 种复种方式 +6 种无氮素处理对照), 表 1 为小区不同处理方式及其标记, 每个小区长 8 m, 宽 5 m, 小区面积 40 m^2 。

1.2 数据采集

1.2.1 无人机数据采集

无人机多光谱图像获取平台采用大疆 Inspire2 无人机搭载 MicaSense RedEdge-MX 型多光谱相机对农田进行采集, 多光谱相机每次拍摄的原始图像尺寸为 1280 像素 \times 960 像素, 相机焦距为 5.5 mm , 视场角为 47.2° , 相机配有标准反射板, 每次采集数据需要对相机进行校正。多光谱相机各通道中心波长与半波宽分别为 Blue: 中心波长 475 nm , 半波宽 20 nm ; Green: 中心波长

560 nm , 半波宽 20 nm ; Red: 中心波长 668 nm , 半波宽 10 nm ; Red-edge: 中心波长 717 nm , 半波宽 10 nm ; NIR: 中心波长 840 nm , 半波宽 40 nm 。无人机数据获取日期为 2022 年 4 月 26 日、5 月 5 日、5 月 15 日、5 月 26 日、6 月 2 日。为保证数据质量, 每次拍摄时间为 11: 00—15: 00 之间, 设定无人机自动巡航的飞行区域为 $60\text{ m} \times 60\text{ m}$, 飞行高度 25 m , 飞行速度 2 m/s , 航向重叠率 85%, 旁向重叠率 80%, 相机垂直拍摄, 拍照间隔时间 1 s。

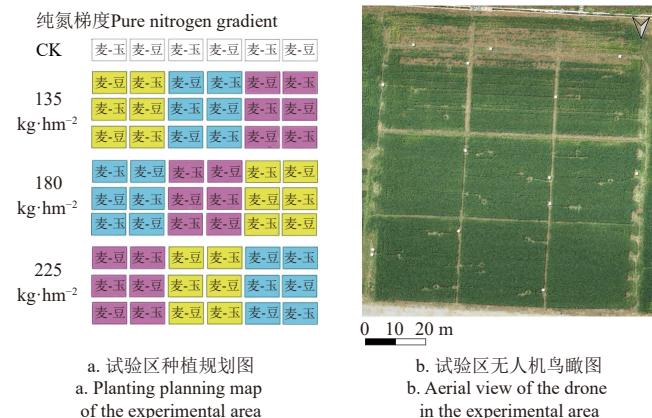


图 1 试验区域及种植图
Fig.1 Experimental area and planting map

表 1 试验设计

Table 1 Design of experiments

处理 Treatment	施氮量 Nitrogen application rate/ (kg/hm ²)	施氮方式 Nitrogen fertilization method	复种方式 Multiple cropping
CK-M	/	/	冬小麦-玉米复种
CK-S	/	/	冬小麦-大豆复种
9U-M	135	普通尿素	冬小麦-玉米复种
9U-S	135	普通尿素	冬小麦-大豆复种
9US-M	135	尿: 缓 1: 1	冬小麦-玉米复种
9US-S	135	尿: 缓 1: 1	冬小麦-大豆复种
12U-M	180	普通尿素	冬小麦-玉米复种
12U-S	180	普通尿素	冬小麦-大豆复种
12US-M	180	尿: 缓 1: 1	冬小麦-玉米复种
12US-S	180	尿: 缓 1: 1	冬小麦-大豆复种
15U-M	225	普通尿素	冬小麦-玉米复种
15U-S	225	普通尿素	冬小麦-大豆复种
15US-M	225	尿: 缓 1: 1	冬小麦-玉米复种
15US-S	225	尿: 缓 1: 1	冬小麦-大豆复种

1.2.2 地面数据采集

地面数据采集在无人机数据获取当天同步完成, 采集 3 个重复小区下, 不同处理标记的小区样品, 在每个小区固定采样点。实验室测定样品的 LAI, 测量方式: 使用比叶重法测定, 在采集干物质样品时, 记录取样面积和取样的总株数。选取样品 5 株, 摘下所有绿色叶片, 使用 1 cm 直径的打孔器对叶片宽窄一致的地方进行打孔, 计算打下圆形叶片面积后将其烘干称质量, 剩余叶片烘干后称质量。计算公式如下:

$$I_{\text{LAI}} = \frac{W_1 + W_2}{A \cdot W_1} \cdot S \cdot m$$

式中 W_1 为圆形叶片面积烘干后质量, g ; W_2 为去除打

孔面积后剩余叶片烘干后质量, g; A 为取样面积, cm^2 ; m 为取样的总株数; S 为打孔圆形叶片面积, cm^2 。

1.3 研究方法

1.3.1 数据预处理与特征提取

图 2 展示了本文的技术路线, 将无人机拍摄的多光谱图像导入到 Pix4Dmapper 软件中, 利用多光谱相机厂家提供的标定系数依次对冬小麦多光谱单幅影像进行标定, 依据对应的位置与姿态数据生成稀疏点云, 采用多视点立体匹配算法生成密集点云数据, 最后导出为 TIFF 格式的数字正射影像 (digital orthophoto map, DOM) 和数字表面模型 (digital surface model, DSM)。生成的多光谱 DOM 影像空间分辨率约为每像素 0.8 cm、其投影坐标系设置为 WGS 1984 坐标系下墨卡托投影分度带的北半区 49°带。对 5 次采样日期的多光谱图像分别框选出地面采样点附近的区域 (不包含地面采样区域), 分割采样区域, 计算采样区域的平均光谱反射率。

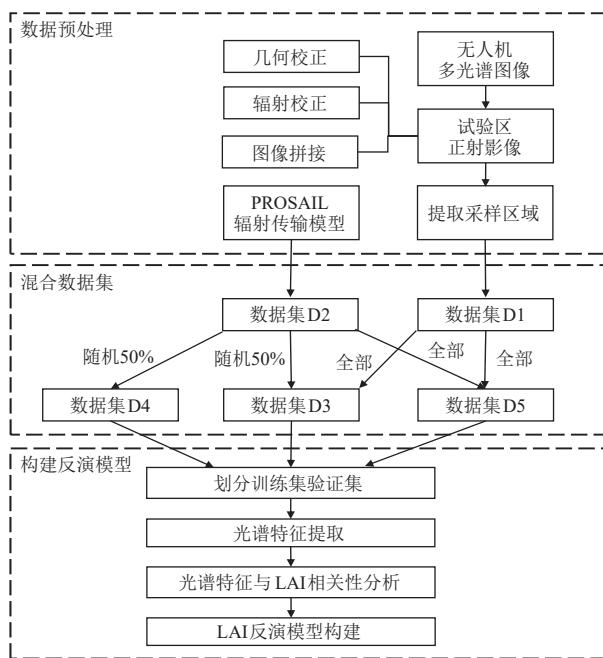


图 2 技术路线图
Fig.2 Technology roadmap

1.3.2 辐射传输模型

PROSAIL 模型是一种广泛应用的辐射传输模型, 可以用于反演植被参数, 如 LAI、叶绿素含量等^[35]。其原理是基于叶片的生物物理特性和冠层的几何结构, 计算不同波长下的太阳辐射在冠层内的多次散射和吸收过程, 从而得到冠层的光谱反射率^[36-37]。PROSAIL 模型输入参数包括 LAI、叶绿素、干物质、类胡萝卜素、水分含量等, 输出参数为植被冠层 400~2 500 nm 高光谱反射率曲线。

1.3.3 混合数据集的构建

在使用机器学习建立回归模型时, 往往存在模型解释性差、模型过度依赖数据集、模型的泛化能力差的问题。为了解决这一问题, 本文设置 5 组数据集组合, 见

表 2。

基于以上 5 种数据集组合, 构成 4 种训练-测试组合, 如表 3 所示。C1 表示纯经验模型, C2 表示纯经验数据训练的纯经验模型在其他数据来源数据中的泛化情况, C3、C4 表示半经验半机理混合数据训练的半经验半机理模型在其他数据来源数据中的泛化情况。

表 2 5 种数据集构成

Table 2 Five combinations of data sets

编号 No.	数据集组合 Dataset combination
D1	麦豆+麦玉的试验数据
D2	使用 PROSAIL 生成不同 LAI 梯度的模拟数据集, LAI 变化范围为 [1,6], 间隔 0.02
D3	D1+D2 随机的 50% 数据构成半混合数据集
D4	为被 D3 使用后 D2 剩余的 50% 数据
D5	D1+D2 构成的全混合数据集

表 3 基于数据集的 4 种训练-测试组合

Table 3 Four combinations based on data sets

编号 No.	训练-测试组合 Training-test combination
C1	常规机器学习训练, 训练集和测试集数据随机按 8:2 划分, 训练集采用五折交叉验证训练模型
C2	全部试验数据 D1 做训练, 模拟数据集 D2 做测试
C3	数据集 D1 与部分模拟数据集的混合数据集 D3 做训练, 使用未参与训练的模拟数据集 D4 做预测
C4	数据集 D5 内部随机按 8:2 划分训练集和测试集

1.3.4 冠层光谱特征提取与 LAI 的相关性分析

本文在前人对 LAI 反演估算研究的基础上, 综合考虑 LAI 对 NIR 波段反射率影响较大, 筛选了 7 种 VI, 用于提取冬小麦冠层光谱特征^[38-41], 详见表 4。基于 5 种数据集 D1~D5, 分别构建不同光谱特征与 LAI 的相关系数矩阵 (correlation coefficient matrix, CCM), 分析不同数据组合下不同光谱特征与 LAI 的相关性, 探究光谱特征对 LAI 的影响程度。

表 4 筛选后的 7 种植被指数

Table 4 The 7 vegetation indices filtered in this article

植被指数 Vegetation index	计算公式 Calculation formula
归一化差异植被指数 Normalized difference vegetation index NDVI	$\frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$
增强植被指数 Enhanced vegetation index EVI	$2.5 \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + 6\rho_R - 7.5\rho_B + 1}$
归一化差异红边指数 Normalized difference red edge index NDRE	$\frac{\rho_{NIR} - \rho_{RE}}{\rho_{NIR} + \rho_{RE}}$
比值植被指数 Simple ratio SR	$\frac{\rho_{NIR}}{\rho_R}$
红边叶绿素植被指数 Red edge chlorophyll index RECI	$\frac{\rho_{NIR}}{\rho_R} - 1$
土壤调节植被指数 Soil-adjusted vegetation index SAVI	$1.5 \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R + 0.5}$
结构不敏感色素植被指数 Structure-insensitive pigment index SIPI	$\frac{\rho_{NIR} - \rho_B}{\rho_{NIR} - \rho_R}$

注: ρ_B 、 ρ_R 、 ρ_{RE} 、 ρ_{NIR} 分别表示蓝色、红色、红边、近红外波段的反射率。

Note: ρ_B , ρ_R , ρ_{RE} , ρ_{NIR} represent the reflectance of the blue band, the red band, the red edge (RE) band, and the near infrared (NIR) band, respectively.

将 LAI 由低到高排序, 按照 LAI 值的变化范围等间距分为划分为 3 个等级 S1、S2、S3, 绘制不同采样点五通道光谱反射率与 LAI 的 RADVIZ (radial coordinate visualization) 图, 更直观地反映 LAI 与波段反射率的相对强度。

1.3.5 半经验半机理 LAI 反演模型的构建

本文采用前文构建的 C1~C4 组合训练机器学习模型, 分别采用贝叶斯岭回归 (bayesian ridge regression, BRR)、线性回归 (linear regression, LR)、弹性网络 (elastic net, EN) 和支持向量回归 (support vector regression, SVR) 进行训练建立 LAI 反演模型。

BRR 是一种基于贝叶斯推理的线性回归方法, 能够自动调整正则化参数, 避免过拟合或欠拟合。它可以利用辐射传输模型生成的模拟数据作为先验信息, 提高反演模型的稳定性和鲁棒性。LR 是一种最简单的线性回归方法, 通过最小二乘法拟合数据, 但特点是对异常值敏感。它可以作为一种基准方法, 与其他复杂方法进行比较和评估。

EN 是一种结合了正则化的线性回归方法, 能够有效地处理特征稀疏和多重共线性的问题。它可以降低冠层光谱特征之间的相关性, 提高反演模型的泛化能力和解释性。

SVR 是一种基于支持向量机的非线性回归方法, 通过核函数将数据映射到高维空间, 然后在高维空间中构造最优超平面来拟合数据。它可以处理非线性和高维数据, 提高模型的精度和灵活性。这 4 种机器学习模型具有代表性和普适性, 能够覆盖不同的机器学习任务和数据特征。

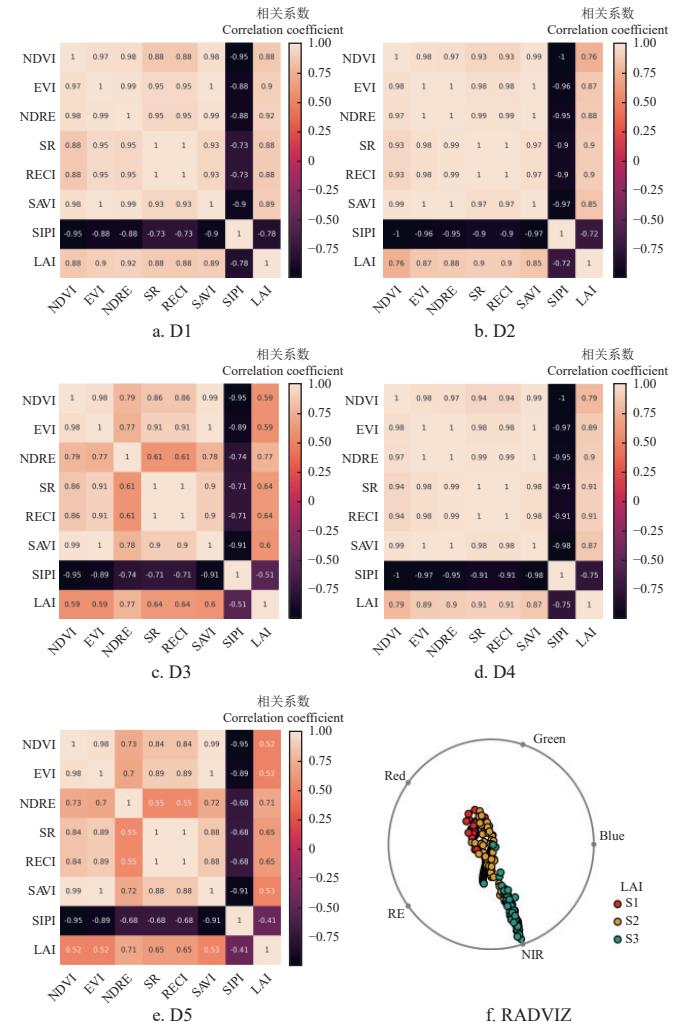
本文使用 Python3.8 编写程序实现模型的建立、结果预测以及制图。使用实测数据、遥感数据及模拟数据进行模型训练和验证, 并采用平均绝对误差 (mean absolute error, MAE)、均方误差 (mean square error, MSE)、均方根误差 (root mean square error, RMSE)、相对均方根误差 (relative root mean square error, RRMSE) 和决定系数 (coefficient of determination, R^2) 作为评价指标。^[42]

2 结果与分析

2.1 冠层光谱特征与 LAI 的相关性

图 3 展示了冠层光谱特征与 LAI 的相关性, 其中图 3a~3e 展示了 D1~D5 中 7 种植被指数 (NDVI、EVI、NDRE、SR、RECI、SAVI、SIPI) 与 LAI 之间的颜色共生矩阵 (color correction matrix, CCM) 热图, SIPI 与 LAI 呈高负相关, 其他 6 种植被指数与 LAI 呈正相关。图 3f 展示了 D5 中不同采样点五通道光谱反射率与 LAI 的径向坐标可视化 (RADVIZ) 图, 其将多维属性映射到二维空间来揭示数据的内在结构, 通过计算在所有特征维度上的加权平均来映射到圆的内部, 用于揭示在 5 个不同波段上的相对强度。图中 LAI 值越大越接近于

NIR 波段, 反映了 NIR 波段对 LAI 的变化较为敏感, 因此基于 NIR 波段计算的 7 种植被指数与 LAI 存在较强的相关性。



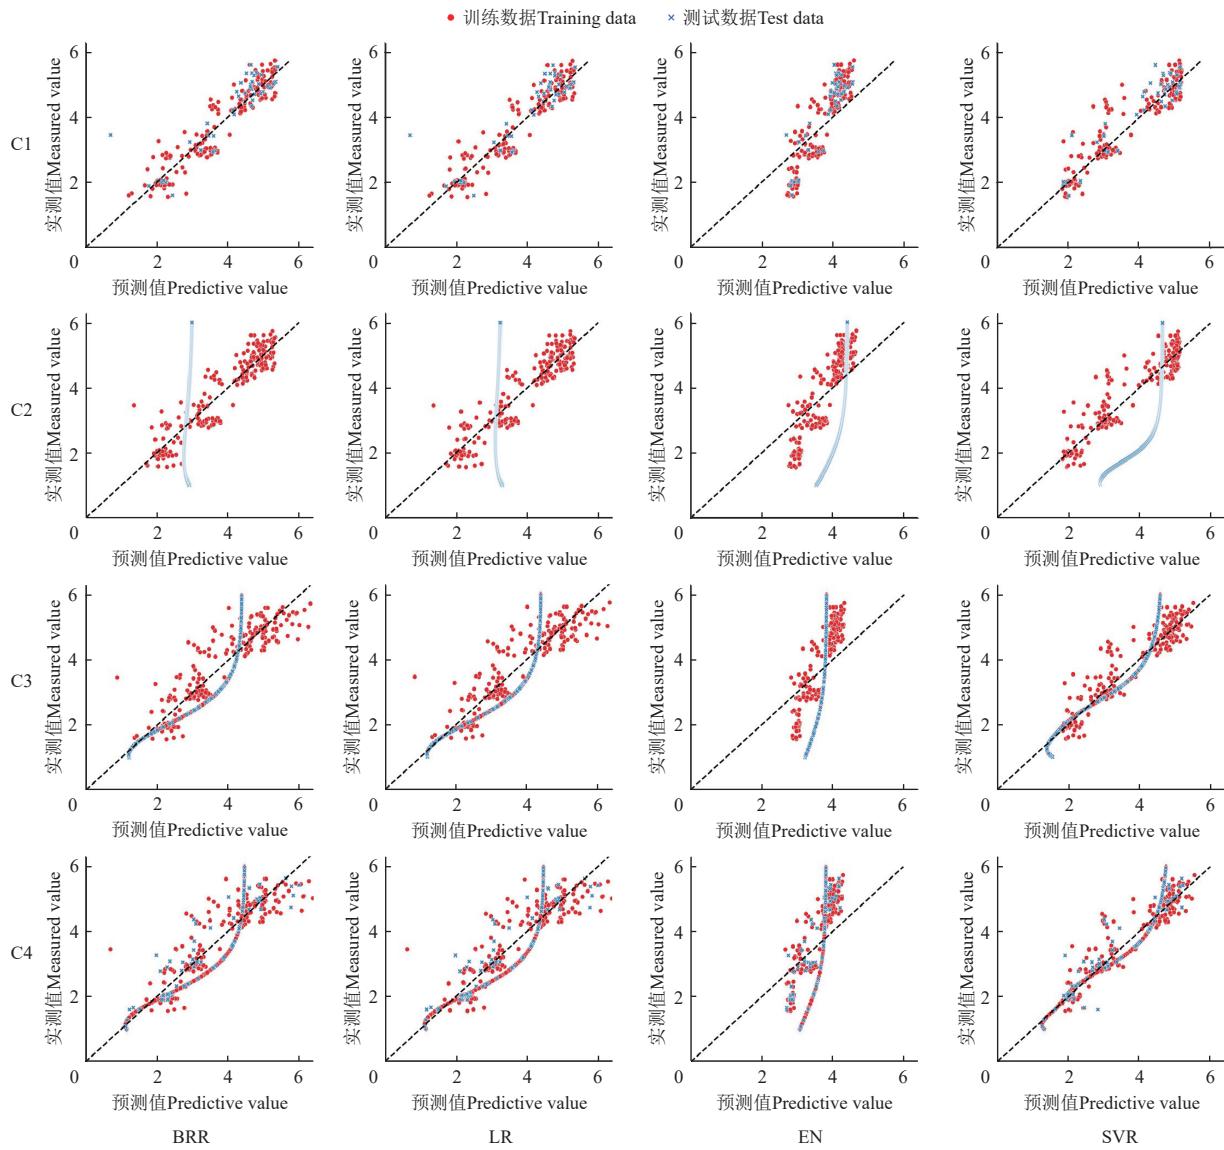
注: S1、S2、S3 为按 LAI 值的变化范围由低到高等间距划分的 3 个等级
Note: S1, S2, and S3 are three levels equally spaced from low to high according to the changing range of LAI values.

图 3 不同数据集冠层光谱特征与 LAI 的相关系数图及 D5 数据集的 RADVIZ 图

Fig.3 Correlation coefficient map between canopy spectral characteristics and LAI in different datasets and RADVIZ map of D5 dataset

2.2 不同机器学习模型的 LAI 反演结果对比

图 4 展示了 C1~C4 不同组合中 BRR、LR、EN、SVR 模型预测值与真值的矩阵散点图, 地面真值 LAI 范围为 1~6。在 C1 和 C3 组合中, EN 预测结果均较为集中, 几乎无法分辨不同特征的差异故效果较差; BRR、LR、SVR 不论是在训练集还是测试集均取得了较好的结果。BRR、LR、EN、SVR 在 C2 组合的测试集中输出结果较差。在 C4 组合中, BRR 与 LR 的预测结果基本相同说明正则化参数对模型输出结果影响不大。这是由于 BRR 不仅给出了权重的点估计, 还给出了权重的后验分布, 可以自动调节正则化参数, 而 LR 使用最大似然估计给出了权重的点估计, 需要手动设置正则化参数。



注: BRR、LR、EN、SVR 分别代表贝叶斯岭回归、线性回归、弹性网络、支持向量回归模型。下同。

Note: BRR, LR, EN, SVR represent the model of Bayesian ridge regression, linear regression, elastic net, and support vector regression. Same below.

图 4 4 种组合中模型预测 LAI 值与真值的矩阵散点图

Fig.4 Matrix scatter plots for predicting LAI values and true values in four combinations of models

4 种模型训练测试结果如表 5 所示。C1 组合中, BRR、LR、EN 的 R^2 在测试集中有明显的下降, 存在过拟合现象, 而 SVR 基本保持了良好的预测性能。C2 组合中, 尽管 BRR、LR、EN、SVR 在训练集取得了较好的结果, R^2 分别为 0.88、0.88、0.63、0.87; RMSE 分别为 0.44、0.44、0.76、0.45, 但在测试集 BRR、LR、EN、SVR 的预测结果非常差, R^2 接近于 0。这说明基于单一来源数据训练的机器学习模型对于其他来源的数据没有预测能力, 说明经验模型易学到片面知识, 致使模型泛化能力较差。C3 组合中, BRR、LR、SVR 在训练集中 R^2 分别为 0.79、0.79、0.88; RMSE 分别为 0.60、0.60、0.45, 在测试集中 R^2 分别为 0.82、0.82、0.89; RMSE 分别为 0.65、0.64、0.49。这是由于引入了混合数据集, 使模型学习到更加全面的数据, 说明本文构建的半经验半机理模型拥有更强的泛化能力。C4 组合中, BRR、LR、SVR 在训练集和测试集中均取得了较好的结果。

2.3 不同处理下的冬小麦 LAI 评估

为探讨不同施氮量对冬小麦长势的影响, 获取 3 个 N 素水平下, 冬小麦开花后 5 个时期 LAI 变化曲线, 如图 5 所示。从图中看出, 在麦豆复种和麦玉复种的小区, 不同 N 素处理对 LAI 的影响表现出类似的变化规律。相比于对照组 CK, 对冬小麦施加氮素处理能够提高 LAI 值, 此外 180 kg/hm² 施肥量比 135 kg/hm² 施肥量效果更好, 但 225 kg/hm² 施肥量与 180 kg/hm² 施肥量效果类似, 说明作物生长满足 N 素需求后, 过量施肥并不能提高 LAI。还可以看出, 冬小麦开花后随着时间的推移 LAI 逐渐下降, 这是因为籽粒不断生长, 而茎叶等非生殖器官逐渐衰老, 导致 LAI 下降。LAI 下降会影响光合作用的效率, 从而影响籽粒的灌浆速率和灌浆持续时间, 相比于 CK, 通过施 N 处理可以保持较高的 LAI 水平, 提高冬小麦产量和品质。

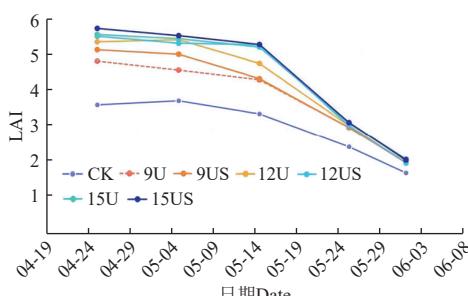
表 5 4 种组合中模型预测结果

Table 5 Model prediction results in four combinations

类型 Type	数据集 Data set	模型 Model	MAE	MSE	RMSE	RRMSE	R^2
C1	训练集	BRR	0.33	0.17	0.41	11.35	0.89
		LR	0.32	0.17	0.41	11.28	0.89
		EN	0.68	0.57	0.76	20.94	0.63
		SVR	0.34	0.22	0.47	12.99	0.86
C2	测试集	BRR	0.38	0.34	0.58	13.95	0.75
		LR	0.38	0.34	0.58	13.88	0.75
		EN	0.73	0.65	0.81	19.28	0.52
		SVR	0.36	0.21	0.45	10.88	0.85
C3	训练集	BRR	0.34	0.19	0.44	11.74	0.88
		LR	0.34	0.19	0.44	11.69	0.88
		EN	0.67	0.58	0.76	20.38	0.63
		SVR	0.33	0.20	0.45	12.08	0.87
C4	测试集	BRR	1.28	2.31	1.52	43.40	-0.10
		LR	1.25	2.13	1.46	41.71	-0.01
		EN	1.23	2.03	1.43	40.75	0.03
		SVR	1.15	1.71	1.31	37.35	0.19
C4	训练集	BRR	0.46	0.36	0.60	16.42	0.79
		LR	0.46	0.36	0.60	16.41	0.79
		EN	0.90	1.06	1.03	28.43	0.38
		SVR	0.32	0.20	0.45	12.46	0.88
C4	测试集	BRR	0.50	0.42	0.65	18.29	0.82
		LR	0.49	0.41	0.64	18.17	0.82
		EN	1.19	1.82	1.35	38.25	0.19
		SVR	0.35	0.24	0.49	14.02	0.89
C4	测试集	BRR	0.46	0.36	0.60	16.73	0.81
		LR	0.46	0.36	0.60	16.72	0.81
		EN	0.95	1.20	1.10	30.75	0.35
		SVR	0.29	0.17	0.41	11.59	0.91
C4	测试集	BRR	0.50	0.39	0.63	16.72	0.79
		LR	0.50	0.39	0.62	16.69	0.79
		EN	0.95	1.21	1.10	29.45	0.36
		SVR	0.36	0.25	0.50	13.27	0.87

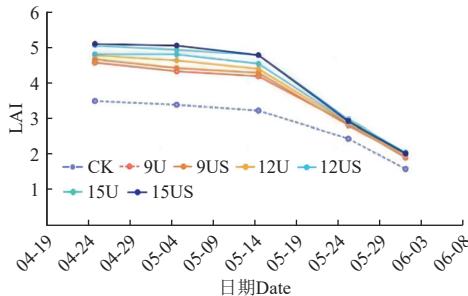
注: MAE 为平均绝对误差、MSE 为均方误差、RMSE 为均方根误差、 $RRMSE$ 为相对均方根误差、 R^2 为决定系数。

Note: MAE is the mean absolute error, MSE is the mean square error, RMSE is the root mean square error, RRMSE is the relative root mean square error, and R^2 is the coefficient of determination.



a. 麦-豆复种

a. Multiple planting of wheat and beans



b. 麦-玉复种

b. Multiple cropping of wheat and maize

图 5 不同 N 素处理下冬小麦 LAI 随时间变化曲线
Fig.5 Time varying curve of wheat LAI under different nitrogen treatments

图 6 给出试验区冬小麦 LAI 反演结果, 可以发现, 在相同 N 素处理下, 麦豆复种方式下的 LAI 值普遍高于麦玉复种, 表现出较好的长势性能。这是因为大豆作为豆科植物, 能够通过根瘤菌固定氮气, 增加土壤氮素含量, 减少水分消耗, 提高有机质输入, 改善土壤环境条件, 提高 LAI 值。

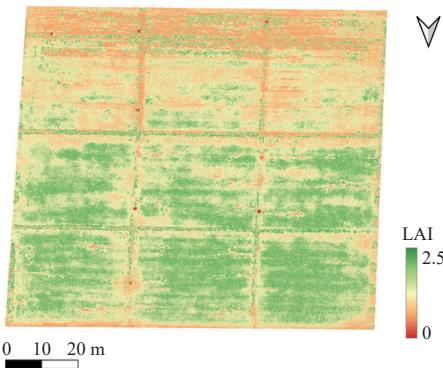


图 6 试验区 LAI 反演地图
Fig.6 LAI inversion map of the experimental area

3 讨论

本文利用半经验半机理建模的方法进行冬小麦 LAI 的反演和长势评估, 与以往的相关研究相比, 具有以下优势:

1) 以往的研究多数基于经验统计模型或物理机理模型进行 LAI 反演, 缺乏对不同数据源之间的融合和利用, 导致模型泛化能力差^[43-45]。而本文结合了无人机多光谱遥感数据和辐射传输模型, 构建了混合数据集, 提高了模型的鲁棒性和泛化能力。相比于单一来源的数据, 混合数据集能够包含更多 LAI 如何影响冬小麦冠层光谱反射率的机理信息, 从而提高反演的精度和可靠性。值得注意的是本文使用的辐射传输模型是基于叶片水平分布假设的 PROSAIL 模型, 而实际上冬小麦叶片并非完全水平分布, 这可能导致模拟数据与真实数据之间存在一定偏差。未来可以考虑使用考虑冬小麦冠层结构特征的辐射传输模型。

2) 本文采用了多种机器学习方法, SVR 模型在各种数据组合下均取得了较好的预测性能。SVR 模型在 C1、C2、C3、C4 这 4 种训练-测试组合的训练集中 R^2 依次为 0.86、0.87、0.88、0.91; RMSE 分别为 0.47、0.45、0.45、0.41, 测试集中 R^2 依次为 0.85、0.19、0.89、0.87; RMSE 分别为 0.45、1.31、0.49、0.50, 这说明 SVR 能够有效地处理非线性关系, 适应不同数据分布, 具有较强的拟合能力和稳定性。未来可以考虑结合其他作物进一步研究, 验证本文结果对其他作物的适用性。

4 结论

本文探讨了基于无人机遥感数据和辐射传输模型的冬小麦 LAI 反演模型, 利用机器学习方法建立了半经验半机理的 LAI 反演模型, 并分析了不同施氮量和复种方式对冬小麦 LAI 的影响。主要结论有:

1) 通过构建混合数据集, 结合试验数据和模拟数据, 可以提高机器学习模型的泛化能力, 使得模型在全新数据集中具有较好的预测性能。在 4 种机器学习模型中, SVR 表现出最优的 LAI 反演效果, 在 C4 组合下训练集中 R^2 为 0.91, RMSE 为 0.41, 测试集中 R^2 为 0.87, RMSE 为 0.50, 其次是 BRR 和 LR, 而 EN 效果较差。在 7 种植被指数中, SIPI 与 LAI 呈高负相关, 其他 6 种植被指数与 LAI 呈正相关。其中, NDRE 与 LAI 的相关性最高, 可以作为 LAI 反演的重要光谱特征。

2) 不同施氮量和复种方式对冬小麦 LAI 的变化有显著影响。相比于对照组 CK, 对冬小麦施加氮素处理能够提高 LAI 值。180 kg/hm² 施肥量比 135 kg/hm² 施肥量效果更好, 但 225 kg/hm² 施肥量与 180 kg/hm² 施肥量效果类似。这说明不能盲目通过增加施肥量提高 LAI。同时, 冬小麦开花后随着时间的推移 LAI 开始逐渐下降, 大量的光合产物供应籽粒的生长, 茎叶等非生殖器官开始逐渐衰老和凋落, 导致 LAI 下降。相比于麦-玉复种方式, 麦-豆复种方式具有更高的生态效益。

[参考文献]

- [1] MA J, WANG L, CHEN P. Comparing different methods for wheat LAI inversion based on hyperspectral data[J]. *Agriculture*, 2022, 12(9): 1353.
- [2] 付波霖, 孙军, 李雨阳, 等. 基于多光谱影像和机器学习算法的红树林树种 LAI 估算[J]. *农业工程学报*, 2022, 38(7): 218-228.
- FU Bolin, SUN Jun, LI Yuyang, et al. Mangrove LAI estimation based on remote sensing images and machinelearning algorithms[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(7): 218-228. (in Chinese with English abstract)
- [3] FASSNACHT K S, GOWER S T, NORMAN J M, et al. A comparison of optical and direct methods for estimating foliage surface area index in forests[J]. *Agricultural and Forest Meteorology*, 1994, 71(1/2): 183-207.
- [4] FANG H, BARET F, PLUMMER S, et al. An overview of global leaf area index (LAI): Methods, products, validation, and applications[J]. *Reviews of Geophysics*, 2019, 57(3): 739-799.
- [5] 李健, 江洪, 罗文彬, 等. 融合无人机多光谱和纹理特征的马铃薯 LAI 估算[J]. *华南农业大学学报*, 2023, 44(1): 93-101.
- LI Jian, JIANG Hong, LUO Wenbin, et al. Potato LAI estimation by fusing UAV multi-spectral and texture features[J]. *Journal of South China Agricultural University*, 2023, 44(1): 93-101. (in Chinese with English abstract)
- [6] 黄梦婷, 张薇, 闫浩迪等. 基于无人机多光谱遥感的水稻冠层 SPAD 值反演[J]. *中国农村水利水电*, 2023(4): 182-188.
- HUANG Mengting, ZHANG Wei, YAN Haodi, et al. Inversion of rice canopy SPAD value based on UAV multispectral remote sensing[J]. *China Rural Water & Hydropower*, 2023(4): 182-188. (in Chinese with English abstract)
- [7] LIU H, LI Q, SHI T, et al. Application of sentinel 2 MSI images to retrieve suspended particulate matter concentrations in Poyang Lake[J]. *Remote Sensing*, 2017, 9(7): 761.
- [8] ZHENG H, CHENG T, YAO X, et al. Detection of rice phenology through time series analysis of ground-based spectral index data[J]. *Field Crops Research*, 2016, 198: 131-139.
- [9] ZHENG H, ZHOU X, CHENG T, et al. Evaluation of a UAV-based hyperspectral frame camera for monitoring the leaf nitrogen concentration in rice[C]//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing, China: IEEE, 2016: 7350-7353.
- [10] DI MAURO B, FAVA F, FERRERO L, et al. Mineral dust impact on snow radiative properties in the European Alps combining ground, UAV, and satellite observations[J]. *Journal of Geophysical Research: Atmospheres*, 2015, 120(12): 6080-6097.
- [11] BRÉDA N J J. Ground - based measurements of leaf area index: A review of methods, instruments and current controversies[J]. *Journal of experimental botany*, 2003, 54(392): 2403-2417.
- [12] LING J, ZENG Z, SHI Q, et al. Estimating winter wheat LAI using hyperspectral UAV data and an iterative hybrid method[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 8782-8794.
- [13] SINGH P, SRIVASTAVA P K, VERRELST J, et al. Estimation of leaf area index using machine learning regression algorithms over agriculture field[C]// Chicago, IL USA, AGU Fall Meeting Abstracts, 2022.
- [14] YAN G, HU R, LUO J, et al. Review of indirect optical measurements of leaf area index: Recent advances, challenges, and perspectives[J]. *Agricultural and Forest Meteorology*, 2019, 265: 390-411.
- [15] 刘涛, 张寰, 王志业, 等. 利用无人机多光谱估算小麦叶面积指数和叶绿素含量[J]. *农业工程学报*, 2021, 37(19): 65-72.
- LIU Tao, ZHANG Huan, WANG Zhiye, et al. Estimation of the leaf area index and chlorophyll content of wheat using UAV multi-spectrum images[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2021, 37(19): 65-72. (in Chinese with English abstract)
- [16] ZHANG S, KORHONEN L, LANG M, et al. The effect of digital hemispherical photograph binarization methods on the estimation of plant area index with lidar data[C]//Berlin, Germany, ForestSat, 2022.
- [17] COHRS C W, COOK R L, GRAY J M, et al. Sentinel-2 leaf area index estimation for pine plantations in the southeastern United States[J]. *Remote Sensing*, 2020, 12(9): 1406.
- [18] WILKINSON M, BELL M C, MORISON J I L. A raspberry Pi - based camera system and image processing procedure for low cost and long - term monitoring of forest canopy dynamics[J]. *Methods in Ecology and Evolution*, 2021, 12(7): 1316-1322.
- [19] YU L, SHANG J, CHENG Z, et al. Assessment of cornfield LAI retrieved from multi-source satellite data using continuous field LAI measurements based on a wireless sensor network[J]. *Remote Sensing*, 2020, 12(20): 3304.

- [20] QU Y, GAO Z, SHANG J, et al. Simultaneous measurements of corn leaf area index and mean tilt angle from multi-directional sunlit and shaded fractions using downward-looking photography[J]. *Computers and Electronics in Agriculture*, 2021, 180: 105881.
- [21] 杨楠,周萌,陈欢,等.基于无人机RGB影像的小麦叶面积指数与产量估算研究[J].麦类作物学报, 2023, 43(7): 920-932.
YANG Nan, ZHOU Meng, CHEN Huan, et al. Estimation of wheat leaf area index and yield based on UAV RGB images[J]. *Journal of Triticeae Crops*, 2023, 43(7): 920-932. (in Chinese with English abstract)
- [22] 张东彦, 韩宣宣, 林芬芳, 等. 基于多源无人机影像特征融合的小麦 LAI 估算[J]. *农业工程学报*, 2022, 38(9): 171-179.
ZHANG Dongyan, HAN Xuanxuan, LIN Fenfang, et al. Estimation of winter wheat leaf area index using multi-source UAV image feature fusion[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2022, 38(9): 171-179. (in Chinese with English abstract)
- [23] 苏伟, 王伟, 刘哲, 等. 无人机影像反演玉米冠层 LAI 和叶绿素含量的参数确定[J]. *农业工程学报*, 2020, 36(19): 58-65.
SU Wei, WANG Wei, LIU Zhe, et al. Determining the retrieving parameters of corn canopy LAI and chlorophyll content computed using UAV image[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2020, 36(19): 58-65. (in Chinese with English abstract)
- [24] 苏宝峰, 刘昱麟, 黄彦川, 等. 群体小麦条锈病发病动态无人机遥感监测方法[J]. *农业工程学报*, 2021, 37(23): 127-135.
SU Baofeng, LIU Yulin, HUANG Yanchuan, et al. Analysis for stripe rust dynamics in wheat population using UAV remote sensing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2021, 37(23): 127-135. (in Chinese with English abstract)
- [25] LI S, YUAN F, Ata-Ul-Karim S T, et al. Combining color indices and textures of UAV-based digital imagery for rice LAI estimation[J]. *Remote Sensing*, 2019, 11(15): 1763.
- [26] WITTSTRUCK L, JARMER T, TRAUTZ D, et al. Estimating LAI from winter wheat using UAV data and CNNs[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [27] 王翔宇, 杨菡, 李鑫星, 等. 基于无人机可见光谱遥感的玉米长势监测[J]. 光谱学与光谱分析, 2021, 41(1): 265-270.
WANG Xiangyu, YANG Han, LI Xinxing, et al. Research on maize growth monitoring based on visible spectrum of UAV remote sensing[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(1): 265-270. (in Chinese with English abstract)
- [28] 徐洪刚, 陈震, 程千, 等. 无人机多源光谱反演大田夏玉米叶面积指数[J]. 灌溉排水学报, 2021, 40(8): 42-49.
XU Honggang, CHEN Zhen, CHENG Qian, et al. Leaf area index of summer maize estimated using UAV-based multispectral imageries[J]. *Journal of Irrigation and Drainage*, 2021, 40(8): 42-49. (in Chinese with English abstract)
- [29] IMPOLLONIA G, CROCI M, BLANDINIÈRES H, et al. Comparison of PROSAIL model inversion methods for estimating leaf chlorophyll content and LAI using UAV imagery for hemp phenotyping[J]. *Remote Sensing*, 2022, 14(22): 5801.
- [30] MAIMAITIJIANG M, GHULAM A, SIDIKE P, et al. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 134: 43-58.
- [31] MIRAGLIO T, ADELIN K, HUESCA M, et al. Monitoring LAI, chlorophylls, and carotenoids content of a woodland savanna using hyperspectral imagery and 3D radiative transfer modeling[J]. *Remote Sensing*, 2019, 12(1): 28.
- [32] PUNALEKAR S M, VERHOEF A, QUAIFE T L, et al. Application of Sentinel-2A data for pasture biomass monitoring using a physically based radiative transfer model[J]. *Remote Sensing of Environment*, 2018, 218: 207-220.
- [33] 于丰华, 白驹驰, 金忠煜, 等. 基于 PROSAIL 模型的水稻叶片生物量反演[J]. 华中农业大学学报, 2023, 42(3): 187-194.
YU Fenghua, BAI Juchi, JIN Zhongyu, et al. Inversion of rice leaf biomass based on PROSAIL model optimization[J]. *Journal of Huazhong Agricultural University*, 2023, 42(3): 187-194. . (in Chinese with English abstract)
- [34] 王枭轩, 卢小平, 杨泽楠, 等. 基于 PROSAIL 结合 VMG 模型的小麦叶面积指数反演方法[J]. *农业机械学报*, 2022, 53(6): 209-216.
WANG Xiaoxuan, LU Xiaoping, YANG Zenan, et al. Retrieving method for leaf area index of winter wheat by combining PROSAIL model with VMG model[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(6): 209-216. (in Chinese with English abstract)
- [35] CHEN Q, ZHENG B, CHEN T, et al. Integration of APSIM and PROSAIL models to develop more precise radiometric estimation of crop traits using deep learning[J/OL]. BioRxiv, 2021: 429471. DOI: 10.1101/2021.02.02.429471.
- [36] BERGER K, ATZBERGER C, DANNER M, et al. Evaluation of the PROSAIL model capabilities for future hyperspectral model environments: A review study[J]. *Remote Sensing*, 2018, 10(1): 85.
- [37] JACQUEMOUD S, VERHOEF W, BARET F, et al. PROSPECT+ SAIL models: A review of use for vegetation characterization[J]. *Remote Sensing of Environment*, 2009, 113: S56-S66.
- [38] CAO X, LIU Y, YU R, et al. A comparison of UAV RGB and multispectral imaging in phenotyping for stay green of wheat population[J]. *Remote Sensing*, 2021, 13(24): 5173.
- [39] ROY B. Optimum machine learning algorithm selection for forecasting vegetation indices: MODIS NDVI & EVI[J]. *Remote Sensing Applications: Society and Environment*, 2021, 23: 100582.
- [40] YAN K, GAO S, CHI H, et al. Evaluation of the vegetation-index-based dimidiate pixel model for fractional vegetation cover estimation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-14.
- [41] SRIVASTAVA P K, GUPTA M, SINGH U, et al. Sensitivity

- analysis of artificial neural network for chlorophyll prediction using hyperspectral data[J]. *Environment, Development and Sustainability*, 2021, 23: 5504-5519.
- [42] 周敏姑, 邵国敏, 张立元等. 无人机多光谱遥感反演冬小麦 SPAD 值[J]. 农业工程学报, 2020, 36(20): 125-133.
- ZHOU Mingu, SHAO Guomin, ZHANG Liyuan, et al. Winter wheat SPAD value inversion using UAV multispectral remote sensing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2020, 36(20): 125-133. (in Chinese with English abstract)
- [43] WU Y, ZHAO Q, YIN X, et al. Multi-Parameter Health Assessment of Jujube Trees Based on Unmanned Aerial Vehicle Hyperspectral Remote Sensing[J]. *Agriculture*, 2023, 13(9): 1679.
- [44] WANG Q, LU X, ZHANG H, et al. Comparison of machine learning methods for estimating leaf area index and aboveground biomass of cinnamomum camphora based on UAV multispectral remote sensing data[J]. *Forests*, 2023, 14(8): 1688.
- [45] 邓尚奇, 赵钰, 白雪源, 等. 基于无人机图像分割的冬小麦叶绿素与叶面积指数反演[J]. *农业工程学报*, 2022, 38(3): 136-145.
- DENG Shangqi, ZHAO Yu, BAI Xueyuan, et al. Retrieval of chlorophyll and leaf area index of winter wheat based on UAV image segmentation[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CASE)*, 2022, 38(3): 136-145. (in Chinese with English abstract)

LAI inversion and growth evaluation of wheat using empirical-mechanistic modeling

LIU Xinzhe¹, WU Lu¹, CHEN Lijin², MA Yufan¹, LI Tao¹, WU Tingting^{1*}

(1. College of Mechanical and Electronic Engineering, Northwest A & F University, Yangling 712100, China;

2. College of Agriculture, Northwest A & F University, Yangling 712100, China)

Abstract: Leaf area index (LAI) is one of the key indicators in the structure and function of vegetation canopy, in order to estimate the biomass and crop growth. This study aims to improve the accuracy and generalization of the LAI inversion model for the winter wheat using unmanned aerial vehicle (UAV) remote sensing. An inversion model was established using semi-empirical and semi-mechanistic approaches. An UAV with a multispectral camera was utilized to obtain the measured data of winter wheat growth with different nitrogen treatments and replanting. PROSAIL radiative transfer model was used to generate the simulated data with mechanistic information. Five LAI inversion hybrid datasets were established using different combinations of measured and simulated data. Various machine learning methods were used to construct a high-precision LAI inversion model using empirical and mechanistic information. Seven kinds of vegetation indices related to NIR bands were screened to extract the winter wheat spectral features, in order to reduce the reflectance of NIR bands. The correlation coefficient matrix between the vegetation indices and the LAI of the mixed dataset was calculated to further explore the degree of influence of different spectral features on the LAI of winter wheat. The LAI inversion models of winter wheat were formed using Bayesian ridge regression, linear regression, elasticity network, and support vector regression model. The feasibility of LAI inversion was also evaluated using semi-empirical and semi-mechanistic data. The ability of the improved model was finally determined to assess the winter wheat growth for different nitrogen levels and replanting. The results showed that: 1) There was a strong correlation between the screened vegetation indices associated with NIR bands and winter wheat LAI. Normalized difference vegetation index (NDVI), enhanced vegetation index (EVI), normalized difference red edge index (NDRE), ratio vegetation index (SR), red edge chlorophyll vegetation index (RECI), and soil adjusted vegetation index (SAVI) were positively correlated with the LAI, whereas, the structurally insensitive pigment vegetation index (SIPI) was negatively correlated with the LAI. 2) The radiative transfer model was represented for the winter wheat LAI subjected to the propagation of solar rays. The strong robustness and generalization were achieved to mix with the measured data. The support vector regression (SVR) model achieved better LAI prediction performance under various data combinations, compared with the rest. In the training set of the four training-test combinations C1, C2, C3 and C4, R^2 is 0.86, 0.87, 0.88, 0.91, RMSE is 0.47, 0.45, 0.45, 0.41; in the test set, R^2 is 0.85, 0.19, 0.89, 0.87, RMSE is 0.45, 1.31, 0.49, 0.50. 3) A support vector machine model was used to generate the LAI inversion maps for the test area. The winter wheat growth was evaluated under four nitrogen levels and two replanting models. The results showed that 180 kg/hm² fertilization was more effective than 135 kg/hm² one, but 225 kg/hm² fertilization was similar to 180 kg/hm² one. An optimal application of nitrogen treatment can be expected to improve the LAI value of winter wheat. Among them, the LAI values under wheat-bean replanting were generally higher than those of wheat-yue replanting. This finding can provide an effective way for the inversion of winter wheat LAI in the efficient assessment of winter wheat growth.

Keywords: UAV; remote sensing; radiation transfer model; vegetation index; LAI inversion; machine learning