doi:10.6041/j.issn.1000-1298.2025.09.045

基于无人机多光谱遥感的覆膜冬小麦叶片含水率反演

谷晓博　徐　洋　程智楷　周智辉　韦春宇　杜娅丹
（西北农林科技大学旱区农业水土工程教育部重点实验室，陕西杨凌 712100）

摘要：精准高效获取作物叶片含水率对于指导农田灌溉具有重要意义。本研究以 2022—2023 年覆膜冬小麦为研究对象，利用无人机搭载多光谱相机采集冬小麦返青、拔节、抽穗、灌浆期的光谱信息，采用极限学习机（ELM）、随机森林（RF）、粒子群优化支持向量机（PSO－SVM）建立冬小麦叶片含水率模型，对比分析以“植被指数＋纹理特征”和“植被指数”为输入变量的叶片含水率反演精度，并通过迭代子集变量优化（IVSO）方法筛选各生育期的特征变量进行重新建模。结果表明，“纹理特征＋植被指数”作为输入变量提高了冬小麦叶片含水率反演精度，极限学习机、随机森林、粒子群优化向量机 R^2 分别平均提高 19.19%、16.85%、19.40%。其中，利用随机森林模型反演覆膜冬小麦叶片含水率的精度在返青–灌浆期最高（训练集 R^2、MAE 和 RMSE 分别为 0.94、0.02 g/g 和 0.03 g/g，测试集 R^2、MAE 和 RMSE 分别为 0.88、0.03 g/g 和 0.05 g/g）；随机森林模型在经过迭代子集变量优化方法后拔节、抽穗和灌浆期的 R^2 分别提高 19.09%、20.58% 和 12.21%。研究结果可为无人机多光谱遥感监测覆膜冬小麦叶片含水率提供理论参考。

关键词：覆膜冬小麦；叶片含水率；无人机多光谱；机器学习；纹理特征；反演
中图分类号：S127；TP79　　**文献标识码**：A　　**文章编号**：1000-1298(2025)09-0547-10　　**OSID**：

Inversion of Leaf Water Content for Mulched Winter Wheat Based on Multi-spectral Remote Sensing of Unmanned Aerial Vehicle

GU Xiaobo　XU Yang　CHENG Zhikai　ZHOU Zhihui　WEI Chunyu　DU Yadan
(*Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas*, *Ministry of Education*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Efficient and accurate acquisition of water content of winter wheat leaves is of great significance in guiding farmland irrigation. Taking 2022—2023 mulched winter wheat as the research object, and a multi-spectral camera mounted on an unmanned aerial vehicle (UAV) was used to collect the spectral information of winter wheat during the greening, nodulation, tasseling, and filling periods, and the background elimination was carried out, and then the extreme learning machines (ELM), random forest (RF), and particle swarm optimization-support vector machine (PSO－SVM) were used to establish a model of leaf water content in winter wheat. Comparative analysis of the accuracy of leaf water content inversion was done by using “vegetation index + texture characteristics” and “vegetation index” as input variables, and re-modeled by filtering the characteristic variables for each fertility period through an iterative subset variable optimization method. The results showed that “texture features + vegetation index” as input variables improved the inversion accuracy of winter wheat leaf water content, and the R^2 of the extreme learning machine, random forest, and particle swarm optimization vector machine was increased by 19.19%, 16.85%, and 19.40% on average, respectively. Among them, the accuracy of the inversion of leaf water content in mulched winter wheat by using the random forest model was the highest in the regrowth-irrigation period (R^2, MAE, and RMSE were 0.94, 0.02 g/g, and 0.03 g/g for the training set, and 0.88, 0.03 g/g, and 0.05 g/g for the test set, respectively); and R^2 for the random forest model was the highest in the nodule pulling, tasseling, and irrigating periods after iterative subset of the variable optimization methods. and grouting stages improved the R^2 by 19.09%, 20.58% and 12.21%, respectively. The results can provide theoretical references for UAV multi-spectral remote sensing to monitor the water content of leaf blades of mulched winter wheat.

Key words: mulched winter wheat; leaf water content; UAV multi-spectral; machine learning; texture feature; inversion

收稿日期：2024－06－17　修回日期：2024－09－18
基金项目：国家重点研发计划项目（2021YFD1900700）和陕西省重点研发计划项目（2023－YBNY－040）
作者简介：谷晓博（1989—），男，教授，博士生导师，主要从事农业节水理论与技术研究，E-mail：guxiaobo@nwafu.edu.cn

0 引言

小麦作为我国主要粮食作物之一,其产量对确保国家粮食安全发挥着至关重要的作用[1]。叶片含水率(Leaf water content,LWC)作为评估作物整体水分状况的重要指标之一,反映了作物生理生长及健康状况,在不同叶片含水率下作物叶片颜色、纹理特征和光谱信息等会发生变化[2]。冬小麦叶片含水率的实时精准监测对优化水分管理、提高作物产量具有重要意义。

烘干法等传统测量叶片含水率的方法虽然结果准确稳定,但耗时较长,并且会对叶片造成一定的破坏[3],无法连续监测作物整个生长周期中的叶片水分变化。尽管卫星遥感技术能够迅速、低成本地捕获到大面积区域的光谱数据,但是其重访周期长,容易受天气因素和云层厚度的影响,难以满足对于高精度农作物反演研究的需求[4],相较于卫星遥感技术,无人机多光谱影像获取影像更为方便,同时还具有低成本、多尺度、多用途以及干扰因素少等优势[5]。近年来,国内外学者基于遥感技术对作物水分含量的快速监测进行了深入研究。利用光谱数据监测作物水分的方法主要有 2 种:①基于经验和半经验的统计方法,即建立参数与光谱数据的回归方程来估算[6-7]。②基于辐射传输模型 PROSAIL[8-9]进行反演。

西北旱区降水稀少,水资源严重短缺[10],粮食产量偏低。地膜覆盖是一种有效的农业节水技术,能够增温保墒[11]、提高作物产量和水分利用效率、抑制杂草生长[12],被誉为“农业的第二次革命”。自 20 世纪 70 年代引入中国以来,塑料薄膜覆盖应用范围从经济作物迅速扩展到粮油作物,地膜覆盖面积从 1993 年的 5.72×10^6 hm^2 激增到 2017 年的 1.866×10^7 hm^2,2017 年地膜用量已超过 1.50×10^6 t,约占世界总用量的 90%[13],地膜覆盖技术已被广泛用于提高旱地农业生态系统的生产力。纹理特征作为重要的遥感信息 ,大多数研究仅利用遥感影像的光谱信息,对于纹理特征与光谱信息联合反演地膜覆盖条件下的冬小麦叶片含水率的相关研究仍较少,地膜覆盖条件下作物叶片含水率的反演模型亟待构建。

本文以覆膜冬小麦返青、拔节、抽穗、灌浆期的遥感数据为基础,采用极限学习机、随机森林、粒子群优化支持向量机建立冬小麦叶片含水率模型,对比分析以“植被指数 + 纹理特征”和“植被指数”为特征变量的叶片含水率反演精度;通过耦合迭代变量子集优化方法筛选变量重新建立模型,以确定覆膜冬小麦叶片含水率的最优模型,旨在为无人机遥感准确预测覆膜冬小麦叶片含水率提供参考。

1 材料与方法

1.1 研究区概况

试验区位于西北农林科技大学旱区农业水土工程教育部重点实验室,地处陕西关中平原中部的杨凌区(34°17′N,108°04′E)(图 1),海拔 521 m,地势平坦,年平均降水量 635 mm,年均气温 12.9℃,属暖温带半湿润半干旱气候区,种植作物以冬小麦和夏玉米为主。冬小麦在 2022 年 10 月中下旬播种,次年 6 月收获。供试土壤为中壤土,其耕层土壤基础理化性质为:有机质 13.40 g/kg,全氮 0.74 g/kg,速效磷 6.79 mg/kg,速效钾 144.76 mg/kg,矿质氮 10.05 mg/kg,平均干容重 1.39 g/cm^3,田间持水率和凋萎系数分别为 24% 和 8.5%(质量分数),pH 值 8.14。试验选用冬小麦品种为“小偃 22”,冬小麦采用垄沟覆膜种植方式,设置 3 个灌溉主区(I0:雨养;I1:越冬期 30 mm,拔节期 30 mm,I2:越冬期 60 mm,拔节期 60 mm),4 个施肥副区(N0:0 kg/hm^2,N1:100 kg/hm^2,N2:200 kg/hm^2,N3:300 kg/hm^2),重复 3 次,共 36 个小区。

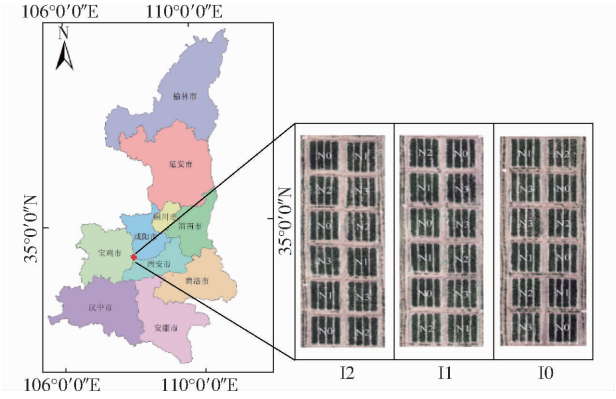


图 1 研究区概况

Fig. 1 Schematic of study area

1.2 地面数据采集与处理

分别在冬小麦返青期、拔节期、抽穗期和灌浆期采集冬小麦叶片,将每株植株顶四叶装入样品袋称其鲜质量(LFW),然后放进干燥箱,设置温度为 105℃杀青 0.5 h,再调节至 80℃烘干 24 h 以上,直至恒质量后称其干质量(LDW)。叶片含水率(LWC)计算公式为

$$L_{WC}=\frac{L_{FM}-L_{DM}}{L_{FM}}$$

式中 L_{FM}——顶四叶鲜质量,g

L_{DM}——顶四叶干物质质量,g

L_{WC}——叶片含水率,g/g

1.3　无人机遥感数据采集与处理

本试验采用大疆 P4M 型无人机遥感平台，集成了 1 个可见光相机及 5 个多光谱相机（蓝光（450 nm）、绿光（560 nm）、红光（650 nm）、红边（730 nm）和近红外（840 nm））分别负责可见光成像及多光谱成像。

于冬小麦返青期、拔节期、抽穗期、灌浆期采集多光谱影像数据，其作业日期与冬小麦叶片采样日期一致，具体为 2023 年 3 月 10 日、2023 年 3 月 30 日、2023 年 5 月 11 日、2023 年 5 月 28 日。研究设计飞行高度 20 m，航向重叠率 80%，旁向重叠率 80%，获取影像时选择天气晴朗少云无风，且光辐射强度稳定的情况进行，将获取的无人机影像和控制点的坐标数据导入 Pix4Dmapper 软件对遥感图像进行拼接和控制点的手动配准校正，然后利用 ENVI 5.6 软件合成 5 波段图像，并利用 ENVI 5.6 软件提取并计算 19 种植被指数[14-18]和 8 个纹理特征作为输入变量，植被指数包括增强型植被指数（EVI）、归一化差值植被指数（NDVI）、比值植被指数（RVI）、绿色归一化差值植被指数（GNDVI）、三角植被指数（TVI）、差值植被指数（DVI）、土壤调节植被指数（SAVI）、优化的土壤调节植被指数（OSAVI）、耐大气植被指数（ARVI）、可见大气阻力指数（VARI）、叶绿素吸收反射率指数（MCARI）、转换叶绿素吸收反射指数（TCARI）、绿度指数（GI）、修正简单比率指数（MSR）、归一化绿蓝差异指数（NGBDI）、归一化红绿差异指数（NGRDI）、过绿指数（EXG）、过红指数（EXR）、非线性植被指数（NLI），纹理特征包括均值（Mean）、方差（Var）、协同性（Hom）、对比度（Con）、相异性（Dis）、信息熵（Ent）、二阶矩（Sec）和相关性（Corr）。

1.4　模型构建与评价指标

覆膜冬小麦叶片含水率数据共计 144 个样本，返青、拔节、抽穗、灌浆期各 36 个样本，按照比例 7∶3 划分训练集和测试集。基于 Matlab 2022a 选择极限学习机[16]（Extreme learning machines，ELM）、随机森林[19]（Random forest，RF）和粒子群优化支持向量机[20]（Particle swarm optimization-support vector machines，PSO－SVM）。选择迭代变量子集优化（Iterative subset variable optimization，IVSO）[21]进行变量筛选。根据皮尔逊相关性分析结果，选择与冬小麦叶片含水率显著相关的植被指数和纹理特征作为输入变量，冬小麦叶片含水率作为输出变量，分别建立冬小麦叶片含水率拔节期、抽穗期、灌浆期以及返青-灌浆期模型。

通过决定系数 R^2、均方根误差 RMSE 和平均绝对误差 MAE 来综合评价模型的建模和验证效果。R^2 越接近 1，RMSE 和 MAE 越接近 0，说明模型效果越好。

2　结果与分析

2.1　地面实测叶片含水率结果分析

总体上，返青（0.764 g/g）、拔节（0.800 g/g）与抽穗（0.784 g/g）3 个生育期冬小麦叶片含水率无显著差异（$P>0.05$），在不同处理间叶片含水率也无明显差异（图 2，图中图柱上的不同小写字母表示同一时期不同处理间差异显著），拔节期的叶片含水率略高于返青期和抽穗期。随生育进程的推进，灌浆期叶片含水率（0.513 g/g）显著低于前 3 个生育期（$P<0.05$），不同处理之间也存在较大差异，其中 I0、I1、I2 处理的叶片含水率分别为 0.584、0.506、0.449 g/g。

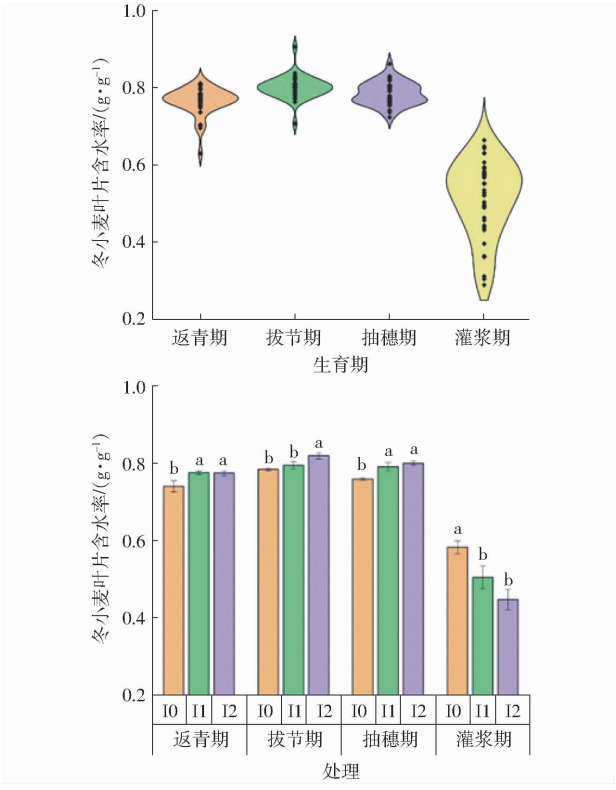


图 2　不同生育期及不同处理冬小麦叶片含水率变化情况

Fig. 2　Trends in leaf water content at different fertility stages and treatments

2.2　不同生育期反射率变化

通过 ENVI 5.6 软件手动划分感兴趣区域（Region of interest，ROI）计算整个地块各个生育期（返青、拔节、抽穗、灌浆期）各个波段（蓝、绿、红、红边、近红外波段）冠层光谱平均反射率平均值（图 3）。不同生育期光谱反射率基本呈现一致的变化规律，即在可见光波段（蓝光、绿光、红光波段）光

谱反射率相对较低，而在近红外波段光谱反射率相对较高，整体呈现“高-低-高”的趋势。

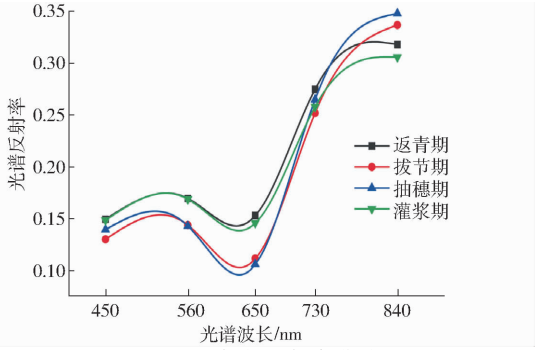


图 3 不同生育期反射率曲线

Fig. 3 Reflectance curves at different fertility stages

2.3 相关性分析

2.3.1 植被指数相关性分析

在冬小麦返青、拔节、抽穗 3 个生育期大部分植被指数与叶片含水率的相关系数逐渐升高，抽穗期和灌浆期植被指数与叶片含水率相关系数相差不大（图 4）。其中抽穗期出现相关系数最大值为 0.536（ARVI），NDVI、RVI、MSR、NRBDI、ARVI、EVI 的相关系数绝对值均在 0.5 以上，TCARI/OSAVI 在各个生育期相关系数均较低，在各个生育期相关系数较高的植被指数中大多包含近红外波段，例如 ARVI 和 NDVI 等，在可见光波段的植被指数与叶片含水率相关性较低，表明在近红外波段包含更多作物生长信息。

2.3.2 纹理特征相关性分析

在冬小麦返青、拔节、抽穗 3 个生育期大部分纹理特征与叶片含水率的相关系数逐渐升高，灌浆期和抽穗期纹理特征与叶片含水率的相关性基本表现一致（图 5）。在拔节期 Con、Dis、Ent 3 个纹理特征在 5 个波段均与叶片含水率显著相关，其中相关系数最高为 0.421；抽穗期相关系数较高的纹理特征主要集中在蓝光波段（450 nm）与红边波段（730 nm），且多数相关系数绝对值大于 0.5，相关系数最高的为蓝光波段 Con 特征（0.558）；灌浆期与拔节、抽穗期相比，大多数纹理特征与叶片含水率表现为显著负相关，相关系数绝对值较高的主要集中在蓝光、红光、近红外波段，蓝光波段 Con 特征也在灌浆期中相关系数最大（-0.544）。

2.4 建模结果分析

根据上述相关性分析的结果，冬小麦返青期的植被指数与纹理特征均无与叶片含水率显著相关的特征变量，因此不单独建立返青期叶片含水率模型。

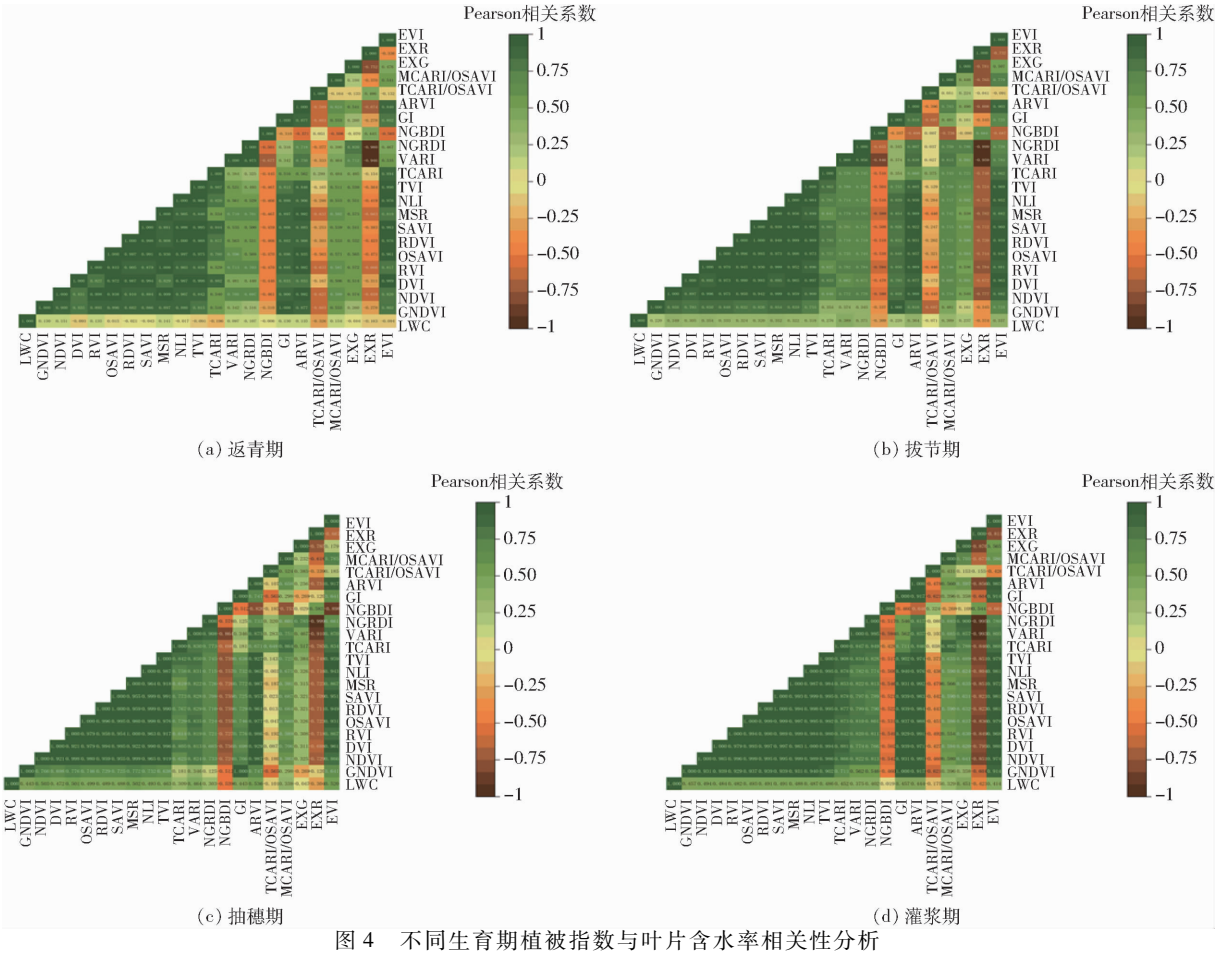


图 4 不同生育期植被指数与叶片含水率相关性分析

Fig. 4 Correlation analysis between vegetation index and leaf water content at different fertility stages

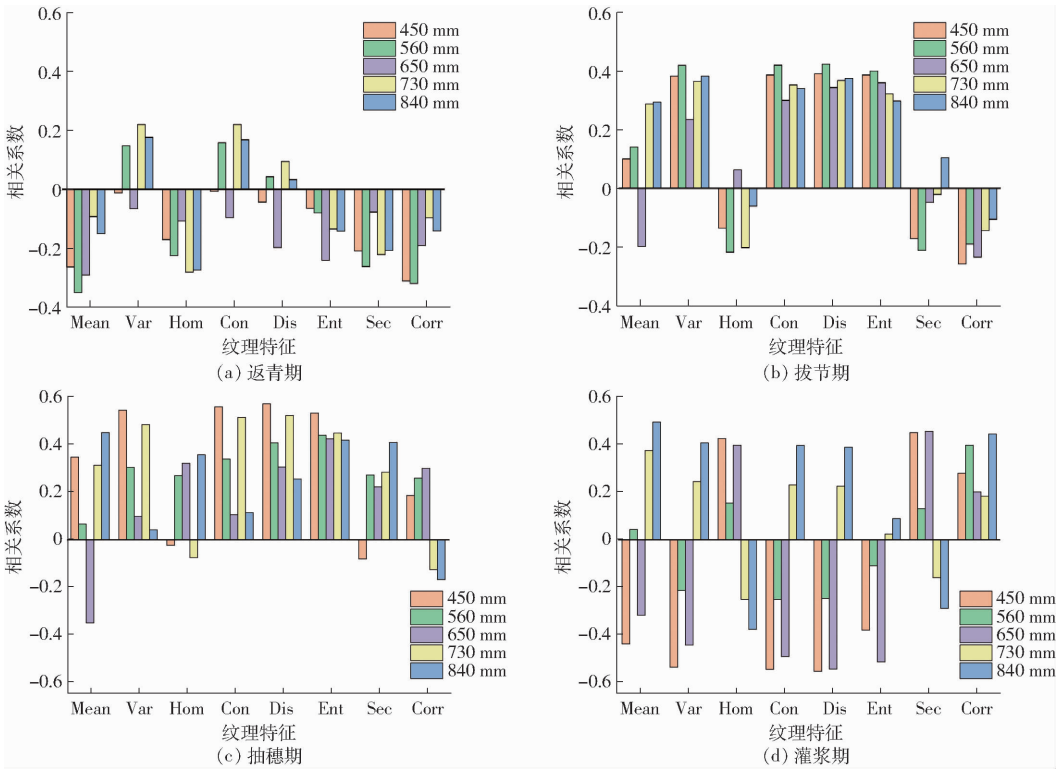


图 5　不同生育期纹理特征与叶片含水率相关性分析

Fig. 5　Correlation analysis between textural characteristics and leaf water content at different fertility stages

将“植被指数 + 纹理特征”作为输入变量，随生育期的推进，3 种机器学习方法叶片含水率反演精度总体上不断提高（表 1），3 种模型的 R^2 为 0.23 ~ 0.94，在拔节期 3 种模型的反演精度均较差。拔节、抽穗、灌浆期反演精度最高的均为随机森林模型，极限学习机模型在 3 个生育期的反演精度均较差（图 6）。返青–灌浆期 3 种模型反演精度显著高于单生育期的反演精度，训练集与测试集 R^2 均在 0.8 以上，其中返青–灌浆期的随机森林模型反演精度最高（训练集 R^2、MAE 和 RMSE 分别为 0.94、0.02 g/g 和 0.03 g/g，测试集 R^2、MAE 和 RMSE 分别为 0.88、0.03 g/g 和 0.05 g/g）。

表 1　“植被指数 + 纹理指数”建模精度评价

Tab. 1　Evaluation of modeling accuracy of “vegetation index + texture index”

生育期	模型	R^2		MAE/(g·g^{-1})		RMSE/(g·g^{-1})	
		训练集	测试集	训练集	测试集	训练集	测试集
返青–灌浆期	ELM	0.92	0.81	0.03	0.04	0.04	0.06
	RF	0.94	0.88	0.02	0.03	0.03	0.05
	PSO – SVM	0.90	0.89	0.02	0.02	0.04	0.04
拔节期	ELM	0.43	0.27	0.01	0.02	0.02	0.03
	RF	0.38	0.43	0.02	0.01	0.03	0.01
	PSO – SVM	0.23	0.32	0.02	0.01	0.03	0.01
抽穗期	ELM	0.49	0.36	0.01	0.02	0.02	0.03
	RF	0.66	0.48	0.01	0.02	0.02	0.02
	PSO – SVM	0.46	0.47	0.01	0.02	0.02	0.02
灌浆期	ELM	0.51	0.48	0.05	0.06	0.07	0.07
	RF	0.70	0.63	0.05	0.04	0.06	0.05
	PSO – SVM	0.56	0.59	0.04	0.05	0.07	0.06

仅以“植被指数”作为输入变量，从整体上看反演精度随生育期的推进逐渐升高（表 2），3 种反演模型 R^2 为 0.15 ~ 0.91，其中反演精度最高的为返青–灌浆期的随机森林模型（训练集 R^2、MAE 和 RMSE 分别为 0.91、0.02 g/g 和 0.04 g/g，测试集 R^2、MAE 和 RMSE 分别为 0.88、0.03 g/g 和 0.05 g/g），拔节、抽穗、灌浆期反演精度最高的是随机森林模型，其余 2 种模型反演精度较差。

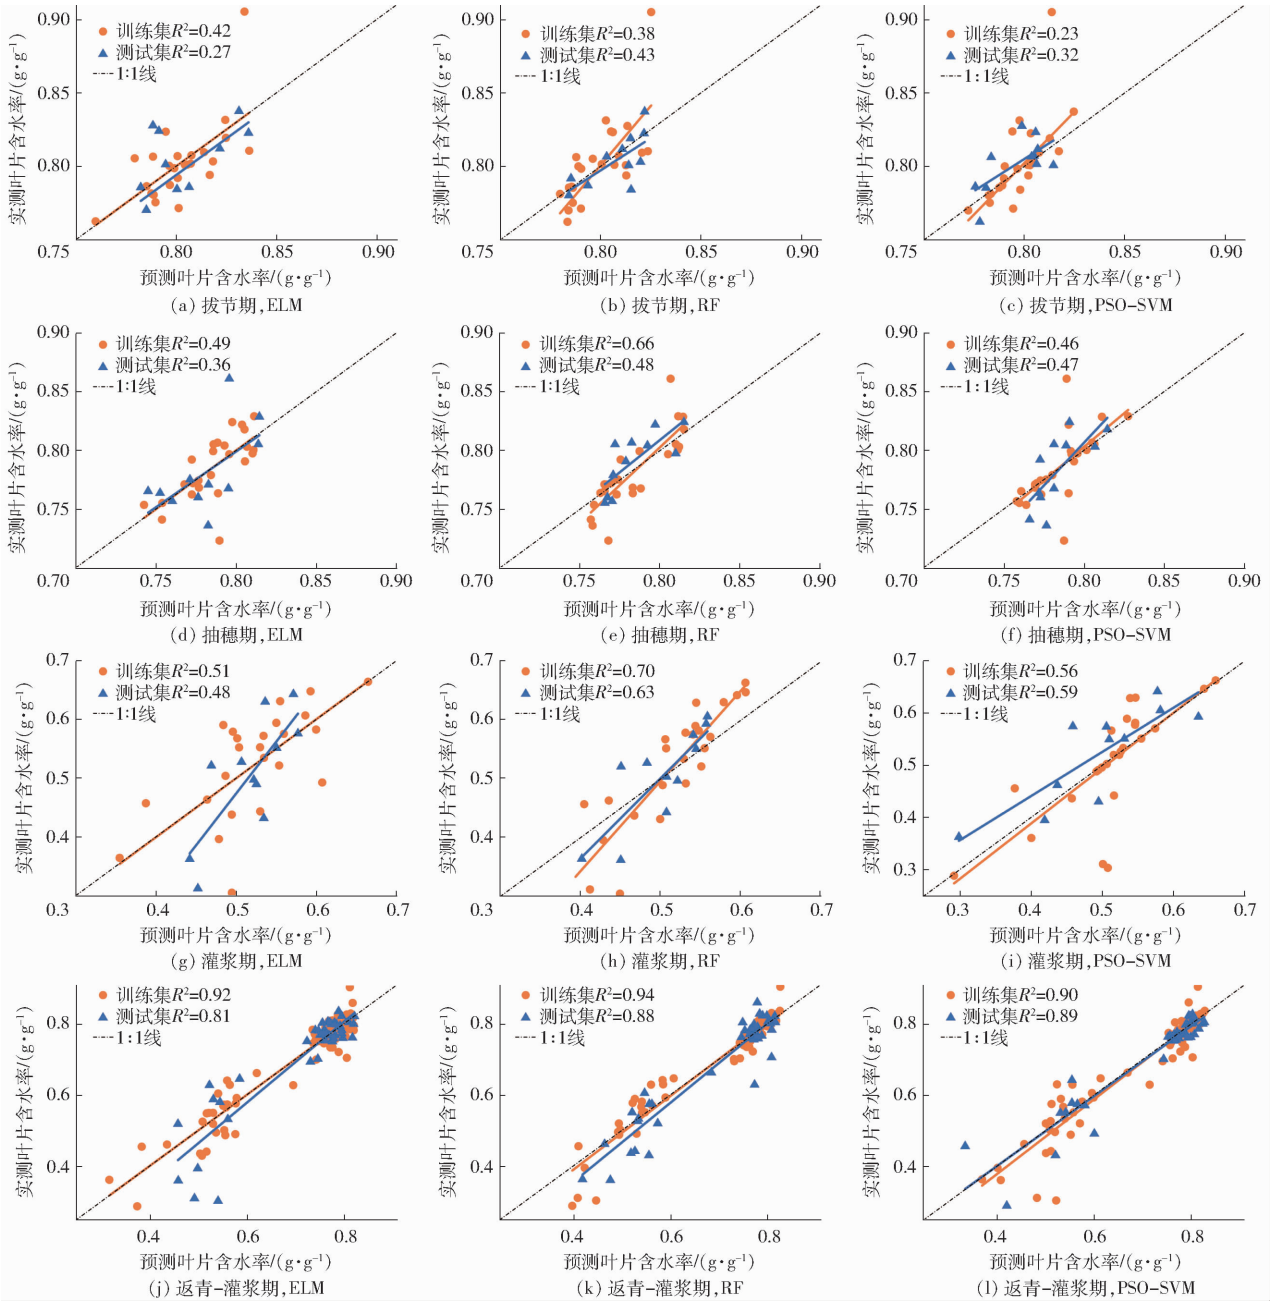


图 6 基于 ELM、RF 和 PSO－SVM 的拔节、抽穗、灌浆及返青-灌浆期冬小麦叶片含水率估测模型

Fig. 6 Model for estimating water content of winter wheat leaves at nodulation, tasseling, filling and whole life stages based on ELM, RF and PSO－SVM

表 2 仅以“植被指数”建模精度评价

Tab. 2 Evaluation of modeling accuracy by “vegetation index” only

生育期	模型	R^2		MAE/(g·g⁻¹)		RMSE/(g·g⁻¹)	
		训练集	测试集	训练集	测试集	训练集	测试集
返青-灌浆期	ELM	0.85	0.83	0.03	0.04	0.05	0.05
	RF	0.91	0.88	0.02	0.03	0.04	0.05
	PSO－SVM	0.91	0.82	0.02	0.03	0.04	0.04
拔节期	ELM	0.17	0.32	0.02	0.01	0.03	0.02
	RF	0.40	0.23	0.02	0.01	0.03	0.01
	PSO－SVM	0.15	0.34	0.02	0.01	0.03	0.02
抽穗期	ELM	0.41	0.39	0.01	0.02	0.02	0.02
	RF	0.57	0.48	0.02	0.01	0.02	0.02
	PSO－SVM	0.47	0.32	0.01	0.02	0.02	0.02
灌浆期	ELM	0.34	0.43	0.06	0.06	0.08	0.08
	RF	0.66	0.41	0.05	0.05	0.06	0.06
	PSO－SVM	0.44	0.33	0.04	0.08	0.07	0.10

与仅以“植被指数”作为输入变量相比，将“植被指数 + 纹理特征”作为输入变量在单生育期和返青–灌浆期均提高了反演精度。抽穗期极限学习机模型训练集 R^2 由 0.41 提升至 0.49，灌浆期随机森林模型测试集 R^2 由 0.41 提升至 0.63，极限学习机、随机森林、粒子群优化向量机的 R^2 平均提高 19.19%、16.85%、19.40%。

通过耦合迭代变量子集优化方法后提取“植被指数 + 纹理特征”作为输入变量（表 3），冬小麦叶片含水率作为输出变量，反演精度随着生育期的推进呈现升高的趋势（表 4），其中在拔节、抽穗、灌浆期反演精度较好的也为随机森林模型（图 7），其中反演精度最高的为返青–灌浆期的随机森林模型（训练集 R^2、MAE 和 RMSE 分别为 0.95、0.02 g/g 和 0.03 g/g，测试集 R^2、MAE 和 RMSE 分别为 0.88、0.03 g/g 和 0.05 g/g）。

表 3　迭代变量子集优化方法筛选变量结果

Tab. 3　Results of screening variables by iterative variable subset optimization methods

生育期	数量	筛选结果
拔节期	7	RVI、ARVI、Con_B1、Dis_B3、Ent_B3、Con_B4、Dis_B5
抽穗期	13	DVI、TCARI、GI、Mean_B1、Con_B1、Dis_B1、Dis_B2、Mean_B3、Ent_B3、Con_B4、Dis_B4、Mean_B5、Ent_B5
灌浆期	14	GNDVI、DVI、OSAVI、SAVI、TVI、NGRDI、EXR、EVI、Hom_B1、Ent_B1、Corr_B1、Var_B3、Con_B3、Dis_B3
返青–灌浆期	31	RVI、OSAVI、RDVI、NLI、TVI、VARI、GI、ARVI、MCARI/OSAVI、EXR、Con_B1、Dis_B1、Ent_B1、Mean_B2、Dis_B2、Sec_B2、Var_B3、Hom_B3、Con_B3、Dis_B3、Ent_B3、Corr_B3、Mean_B4、Hom_B4、Dis_B4、Ent_B4、Sec_B4、Hom_B5、Dis_B5、Sec_B5、Corr_B5

表 4　耦合迭代变量子集优化方法后建模精度评价

Tab. 4　Evaluation of modeling accuracy after coupled iterative variable subset optimization methods

生育期	模型	R^2		MAE/(g·g^{-1})		RMSE/(g·g^{-1})	
		训练集	测试集	训练集	测试集	训练集	测试集
返青–灌浆期	ELM	0.89	0.83	0.04	0.03	0.05	0.05
	RF	0.95	0.88	0.02	0.03	0.03	0.05
	PSO – SVM	0.90	0.87	0.03	0.03	0.04	0.05
拔节期	ELM	0.27	0.41	0.02	0.01	0.03	0.02
	RF	0.56	0.44	0.01	0.01	0.02	0.02
	PSO – SVM	0.40	0.15	0.01	0.02	0.03	0.02
抽穗期	ELM	0.52	0.30	0.02	0.02	0.02	0.03
	RF	0.74	0.69	0.01	0.01	0.02	0.01
	PSO – SVM	0.53	0.40	0.01	0.02	0.02	0.02
灌浆期	ELM	0.49	0.52	0.05	0.06	0.07	0.07
	RF	0.77	0.75	0.04	0.04	0.05	0.04
	PSO – SVM	0.41	0.52	0.05	0.07	0.07	0.07

对比以“植被指数 + 纹理特征”作为输入变量的反演精度，各机器学习方法表现出不同的效果，3 种模型在返青–灌浆期的反演精度相差不大，随机森林模型在拔节、抽穗和灌浆期的 R^2 分别提高 19.09%、20.58% 和 12.21%，对于极限学习机模型与粒子群优化支持向量机模型，二者的反演精度无明显提升，灌浆期粒子群优化支持向量机模型的反演精度降低。

3　讨论

3.1　加入纹理特征后建模差异

对比“植被指数 + 纹理特征”与仅通过“植被指数”为输入的叶片含水率反演精度，以“植被指数 + 纹理特征”作为输入变量在全生育期和单生育期的反演精度均有不同程度提升，极限学习机、随机森林、粒子群优化向量机 R^2 平均提高 19.19%、16.85%、19.40%，原因可能是纹理特征反映了灰度图像中不同强度的相似图案在局部区域的结构或排列规律[22]，能够有效地表现冬小麦的空间分布特征，这一信息有助于减轻生长后期冠层光谱饱和所引发的监测精度下降问题。ZHAO 等[23]研究表明“植被指数 + 纹理指数”组合构建模型对随机森林模型 R^2 的提高幅度为 8.5%，对极限学习机模型 R^2 的提高幅度为 15.8%，纹理信息与植被指数的结合提高了苜蓿土壤含盐量的反演精度；杭艳红等[24]在结合无人机光谱信息、纹理特征和覆盖度估算水稻叶面积指数时也得到了相似的结论。本研究中，3 种建模方式（“植被指数”、“植被指数 + 纹理特征”、迭代子集变量优

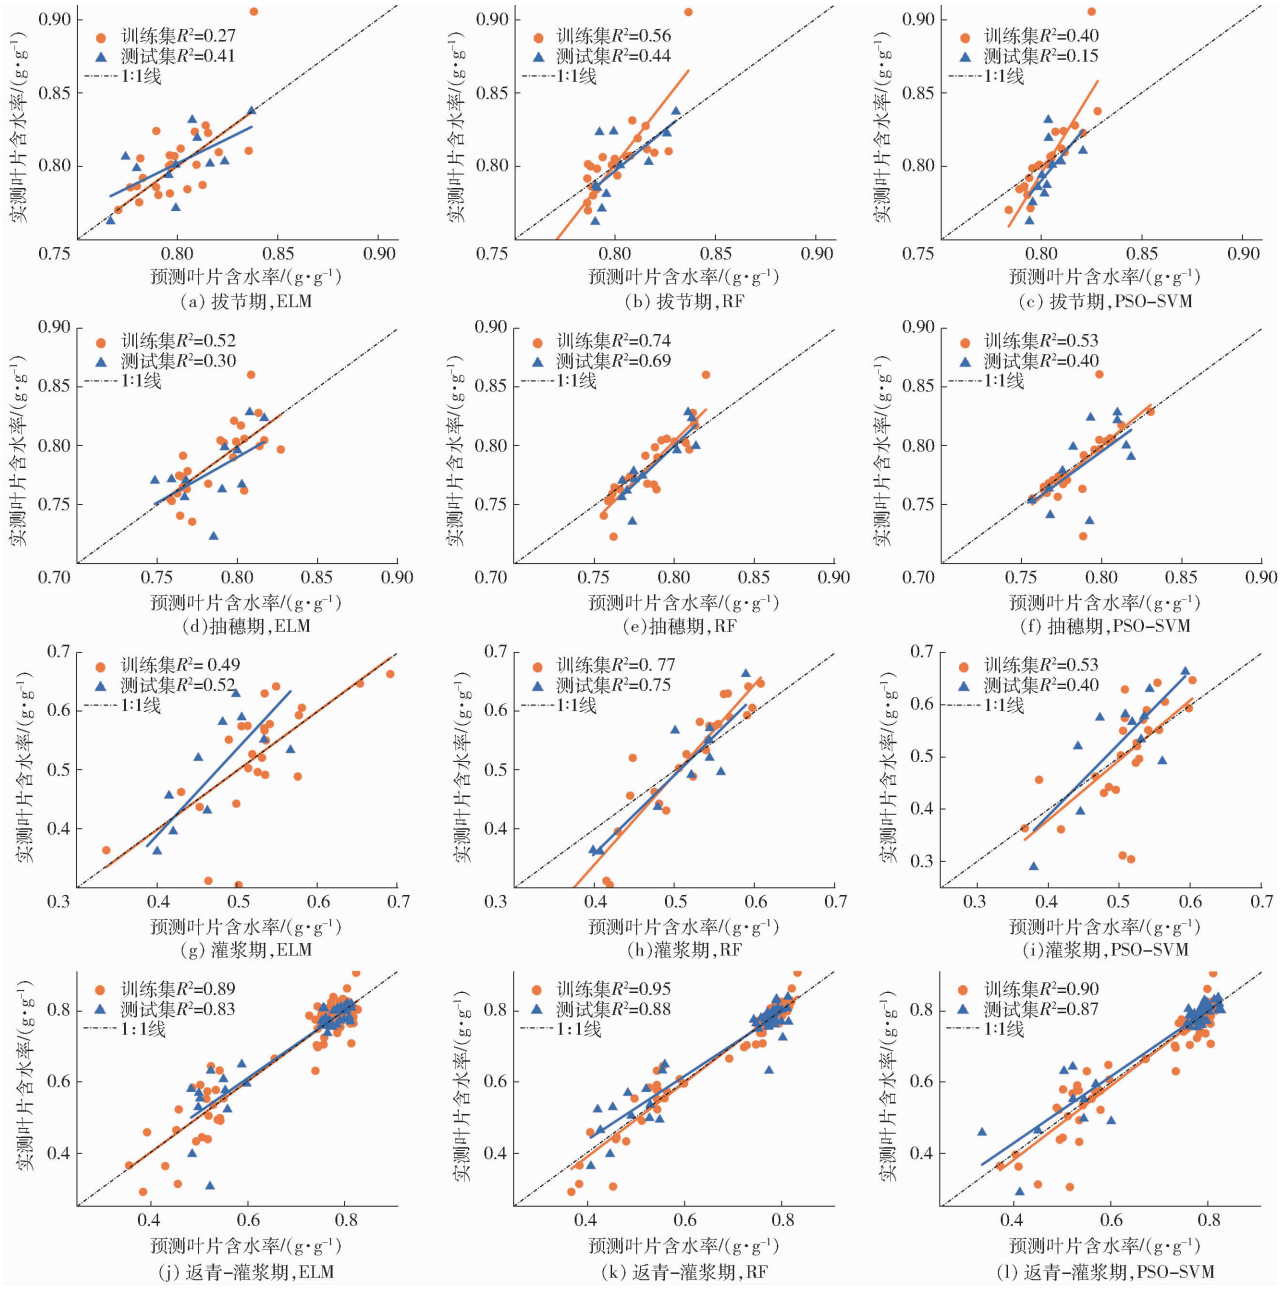


图 7 耦合迭代变量子集优化方法后拔节、抽穗、灌浆及返青-灌浆期冬小麦叶片含水率估测模型

Fig. 7 Model for estimating water content of winter wheat leaves at nodulation, tasseling, and filling stages after coupled iterative subset optimization of variables

化后筛选的“植被指数 + 纹理特征”)的叶片含水率反演精度均呈随生育期的推进逐渐提高的趋势,这可能是因为各生育期冬小麦的冠层结构不同,使用无人机获取光谱信息(植被指数、纹理特征)存在差异[15],因此构建的模型在不同生育期具有不同的反演精度,冬小麦在拔节期分蘖数、叶面积指数较小,遥感影像受到地膜、土壤等背景的干扰较大且冠层光谱对冬小麦叶片含水率的表征能力不足,由于地膜、土壤与冬小麦“混合像元[25]”的存在导致地膜边缘的剔除效果较差,因此拔节期反演精度较差,在抽穗期和灌浆期由于受到“混合像元”的干扰较小,因此建模精度较高。另外,已有研究表明,在不同地面分辨率下,图像的纹理特征与作物生长指标之间有较大差异[26],因此后续应进一步研究不同分辨率下纹理特征的建模差异。

3.2 变量筛选及不同机器学习方法建模差异

运用迭代变量子集优化方法筛选变量,随着拔节、抽穗、灌浆 3 个生育期的推进,筛选出的植被指数所占比例提高,纹理特征所占比例降低,另外各个生育期筛选出的植被指数大多包含近红外波段,一方面可能是因为作物叶片含水量的变化对近红外波段的光谱反射率有较大影响[27],另一方面各生长阶段所筛选出的植被指数和纹理特征的差异反映了冬小麦在可见光谱和近红外谱段的差异性。对反演结

果进行分析后发现，无论输入特征变量是否加入纹理特征，随机森林一直都是 3 个模型当中表现最佳的模型，主要原因是随机森林算法自身的优越性[28]，且具有更好的稳定性[29]，已有研究表明随机森林模型在估算农田土壤含盐量[30]、冬小麦产量[31]、棉花叶面积指数[32]均有较高的精度。极限学习机反演精度较差，原因可能是其表示非线性模型的能力较差，虽然粒子群优化支持向量机模型已经对惩罚系数、损失函数以及核系数进行参数优化，但由于本试验样本数量较少，导致其在单生育期的反演精度不高。

通过迭代变量子集优化的方法重新建立模型后，随机森林模型反演精度在拔节、抽穗、灌浆期均有提升。但对于另外 2 种模型无明显提升，其中灌浆期的粒子群优化支持向量机经过迭代变量子集优化后的反演精度甚至还有些下降。这可能是因为变量筛选方法不适用于所有的机器学习算法，且迭代变量子集优化方法与机器学习算法的原理不同，导致不同机器学习方法与迭代变量子集优化方法的耦合模型存在较大差异[26]。

目前，多源数据的特征融合已然成为无人机多光谱遥感反演作物生长指标的热点，已有研究表明将作物模型与无人机遥感数据耦合[33]，将株高等结构特征作为特征变量[34]对模型精度有不同程度的提升。由于本研究仅采用 1 年的数据，导致单生育期的反演精度较差，未来可以选择不同作物品种、不同年限来验证模型以及将多源数据进行特征融合，进而提升模型普适性及鲁棒性。

4　结论

（1）融合“植被指数 + 纹理特征”提高了覆膜冬小麦叶片含水率的反演精度，其中极限学习机、随机森林、粒子群优化向量机的 R^2 分别平均提高 19.19%、16.85%、19.40%。

（2）随机森林模型为反演覆膜冬小麦叶片含水率的最佳模型，在返青—灌浆期反演叶片含水率的精度最高（训练集 R^2、MAE 和 RMSE 分别为 0.94、0.02 g/g 和 0.03 g/g，测试集 R^2、MAE 和 RMSE 分别为 0.88、0.03 g/g 和 0.05 g/g）；经过迭代子集变量优化方法对各生育期的特征变量进行筛选并重新建模后，随机森林模型在拔节、抽穗和灌浆期的 R^2 分别提高 19.09%、20.58% 和 12.21%。

参　考　文　献

[1] YIN Q, ZHANG Y, LI W, et al. Estimation of winter wheat SPAD values based on UAV multispectral remote sensing[J]. Remote Sensing, 2023, 15(14): 3595.

[2] 杨淑婷, 张学俭. 宁南山区土壤含水量遥感监测研究[J]. 宁夏农林科技, 2015, 56(10): 26-28,75.
YANG Shuting, ZHANG Xuejian. Soil moisture monitoring by remote sensing in mountainous area of Southern Ningxia[J]. Ningxia Journal of Agriculture and Forestry Science and Technology, 2015, 56(10): 26-28,75. (in Chinese)

[3] 王聪颖, 罗华平, 高峰,等. 基于近红外光谱技术的杏叶含水率反演研究[J]. 塔里木大学学报, 2023, 35(2): 89-96.
WANG Congying, LUO Huaping, GAO Feng, et al. Study on inversion of apricot leaves moisture content in Southern Xinjiang based on near infrared spectroscopy[J]. Journal of Tarim University, 2023, 35(2): 89-96. (in Chinese)

[4] 吴亚坤, 刘广明, 杨劲松,等. 基于多源数据的中原黄泛区土壤盐分空间变异分析[J]. 农业工程学报, 2015, 31(5): 115-120.
WU Yakun, LIU Guangming, YANG Jinsong, et al. Spatial variability of soil salinity based on multi-source data for typical zone of flood area of the Yellow River in central China[J]. Transactions of the CSAE, 2015, 31(5): 115-120. (in Chinese)

[5] 陈雯, 武威, 孙成明,等. 无人机遥感在作物监测中的应用与展望[J]. 上海农业学报, 2016, 32(2): 138-143.
CHEN Wen, WU Wei, SUN Chengming, et al. Application and prospect of UAV remote sensing in crop monitoring[J]. Acta Agriculturae Shanghai, 2016, 32(2): 138-143. (in Chinese)

[6] MNDELA Y, NDOU N, NYAMUGAMA A. Irrigation scheduling for small-scale crops based on crop water content patterns derived from UAV multispectral imagery[J]. Sustainability, 2023, 15(15): 12034.

[7] TRAORE A, ATA-Ul-KARIM S T, DUAN A, et al. Predicting equivalent water thickness in wheat using UAV mounted multispectral sensor through deep learning techniques[J]. Remote Sensing, 2021, 13(21): 4476.

[8] BARET F, JACQUEMOUD S, GUOT G, et al. Modeled analysis of the biophysical nature of spectral shifts and comparison with information content of broad bands[J]. Remote Sensing of Environment, 1992, 41(2-3): 133-142.

[9] 唐源, 王小平, 鲁聪聪,等. 基于 PROSAIL 模型与光谱指数的紫花苜蓿冠层含水量估算[J]. 兰州大学学报(自然科学版), 2023, 59(1): 55-62.
TANG Yuan, WANG Xiaoping, LU Congcong, et al. Estimating the canopy water content of alfalfa based on the PROSAIL model and spectral index[J]. Journal of Lanzhou University (Natural Sciences), 2023, 59(1): 55-62. (in Chinese)

[10] 张爱辉, 徐梓曜, 王冉,等. 西北旱区大型灌区实施深度节水的生态发展模式探究[J]. 中国水利, 2024(6):61-67.
ZHANG Aihui, XU Ziyao, WANG Ran, et al. Research on ecological development model of deep water-saving in large irrigation areas in northwest arid region[J]. China Water Resources, 2024(6):61-67. (in Chinese)

[11] 牛岸秋, 吴景贵, 赵欣宇. PPC 地膜不同覆盖方式下降解特征的红外光谱分析[J]. 光谱学与光谱分析, 2023, 43(2): 533 – 540.
NIU Anqiu, WU Jinggui, ZHAO Xinyu. Infrared spectral analysis of degradation characteristics of PPC plastic film under with different covering methods[J]. Spectroscopy and Spectral Analysis, 2023, 43(2): 533 – 540. (in Chinese)

[12] 徐守振, 马麒, 孔宪辉,等. 早期揭膜对棉花生育前期土壤水热微环境及其成铃的影响[J]. 中国棉花, 2021, 48(7): 14 – 18.
XU Shouzhen, MA Qi, KONG Xianhui, et al. Effect of early film removing on soil hydrothermal microenvironment and boll formation in the early growth stage of cotton[J]. China Cotton, 2021, 48(7): 14 – 18. (in Chinese)

[13] 国家统计局. 2018 年中国统计年鉴[M]. 北京: 中国统计出版社,2018.

[14] LIU Y, SUN L, LIU B, et al. Estimation of winter wheat yield using multiple temporal vegetation indices derived from UAV-Based multispectral and hyperspectral imagery[J]. Remote Sensing, 2023, 15(19): 4800.

[15] 严海军, 卓越, 李茂娜,等. 基于机器学习和无人机多光谱遥感的苜蓿产量预测[J]. 农业工程学报, 2022, 38(11): 64 – 71.
YAN Haijun, ZHUO Yue, LI Maona, et al. Alfalfa yield prediction using machine learning and UAV multispectral remote sensing[J]. Transactions of the CSAE, 2022, 38(11): 64 – 71. (in Chinese)

[16] 芮婷婷, 徐云飞, 程琦,等. 基于无人机多光谱遥感的冬小麦叶片含水量反演[J]. 麦类作物学报, 2022, 42(10): 1291 – 1300.
RUI Tingting, XU Yunfei, CHENG Qi, et al. Water content retrieval of winter wheat leaves based on UAV multi-spectral remote sensing[J]. Journal of Triticeae Crops, 2022, 42(10): 1291 – 1300. (in Chinese)

[17] 哈布热, 张宝忠, 李思恩,等. 基于冠层光谱特征的冬小麦植株含水率诊断研究[J]. 灌溉排水学报, 2018, 37(10): 9 – 15.
HABURE, ZHANG Baozhong, LI Si'en, et al. Diagnostic study on water content of winter wheat plants based on canopy spectral features[J]. Journal of Irrigation and Drainage, 2018, 37(10): 9 – 15. (in Chinese)

[18] WEI L, YANG H, NIU Y, et al. Wheat biomass, yield, and straw-grain ratio estimation from multi-temporal UAV-based RGB and multispectral images[J]. Biosystems Engineering, 2023, 234: 187 – 205.

[19] 姜友谊, 刘博伟, 张成健,等. 利用无人机多光谱影像的多品种玉米成熟度监测[J]. 农业工程学报, 2023, 39(20): 84 – 91.
JIANG Youyi, LIU Bowei, ZHANG Chengjian, et al. Multi-variety maize maturity monitoring based on UAV multi-spectral images[J]. Transactions of the CSAE, 2023, 39(20): 84 – 91. (in Chinese)

[20] 王晗, 向友珍, 李汪洋,等. 基于无人机多光谱遥感的冬油菜地上部生物量估算[J]. 农业机械学报, 2023, 54(8): 218 – 229.
WANG Han, XIANG Youzhen, LI Wangyang, et al. Estimation of winter rapeseed above-ground biomass based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 218 – 229. (in Chinese)

[21] WANG W, YUN Y, DENG B, et al. Iteratively variable subset optimization for multivariate calibration[J]. RSC Advances, 2015, 5(116): 95771 – 95780.

[22] 王伟康, 张嘉懿, 汪慧,等. 基于固定翼无人机多光谱影像的水稻长势关键指标无损监测[J]. 中国农业科学, 2023, 56(21): 4175 – 4191.
WANG Weikang, ZHANG Jiayi, WANG Hui, et al. Non-destructive monitoring of key growth indicators based on fixed-wing UAV multispectral imagery[J]. Scientia Agricultura Sinica, 2023, 56(21): 4175 – 4191. (in Chinese)

[23] ZHAO W, MA F, YU H, et al. Inversion model of salt content in alfalfa-covered soil based on a combination of UAV spectral and texture information[J]. Agriculture, 2023, 13(8): 1530.

[24] 杭艳红, 苏欢, 于滋洋,等. 结合无人机光谱与纹理特征和覆盖度的水稻叶面积指数估算[J]. 农业工程学报, 2021, 37(9): 64 – 71.
HANG Yanhong, SU Huan, YU Ziyang, et al. Estimation of rice leaf area index combining UAV spectrum, texture features and vegetation coverage[J]. Transactions of the CSAE, 2021, 37(9): 64 – 71. (in Chinese)

[25] 周智辉, 谷晓博, 程智楷,等. 基于影像分割的覆膜玉米叶绿素含量反演[J]. 中国农业科学, 2024, 57(6): 1066 – 1079.
ZHOU Zhihui, GU Xiaobo, CHENG Zhikai, et al. Inversion of chlorophyll content of film-mulched maize based on image segmentation[J]. Scientia Agricultura Sinica, 2024, 57(6): 1066 – 1079. (in Chinese)

[26] ZHOU Y, LAO C, YANG Y, et al. Diagnosis of winter-wheat water stress based on UAV-borne multispectral image texture and vegetation indices[J]. Agricultural Water Management, 2021, 256: 107076.

[27] 刘畅, 孙鹏森, 刘世荣. 植物反射光谱对水分生理变化响应的研究进展[J]. 植物生态学报, 2016, 40(1): 80 – 91.
LIU Chang, SUN Pengsen, LIU Shirong. A review of plant spectral reflectance response to water physiological changes[J]. Chinese Journal of Plant Ecology, 2016, 40(1): 80 – 91. (in Chinese)

(下转第 565 页)

[2023 - 07 - 01]. https://doi.org/10.48550/arXiv.2303.10542.
[31] ZHANG P, LI D. Automatic counting of lettuce using an improved YOLOv5s with multiple lightweight strategies[J]. Expert Systems with Applications, 2023, 226: 120220.
[32] LI Z, LI Y, YANG Y, et al. A high-precision detection method of hydroponic lettuce seedlings status based on improved Faster R - CNN[J]. Computers and Electronics in Agriculture, 2021, 182: 106054.
[33] RADOGLOU-GRAMMATIKIS P, SARIGIANNIDIS P, LAGKAS T, et al. A compilation of UAV applications for precision agriculture[J]. Computer Networks, 2020, 172: 107148.
[34] VARGHESE R, SAMBATH M. YOLO v8: a novel object detection algorithm with enhanced performance and robustness[C]// 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). IEEE, 2024: 1 - 6.
[35] WANG A, CHEN H, LIU L, et al. YOLOv10: real-time end-to-end object detection[J]. arXiv preprint arXiv: 2405. 14458, 2024.
[36] HOWARD A, SANDLER M, CHU G, et al. Searching for Mobilenetv3[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314 - 1324.
[37] WU Y, HEE K. Group normalization[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 - 19.
[38] LIU W, SALZMANN M, FUA P. Context-aware crowd counting[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5099 - 5108.

(上接第 556 页)

[28] 冯浩, 杨祯婷, 陈浩,等. 基于无人机多光谱影像的夏玉米 SPAD 估算模型研究[J]. 农业机械学报, 2022, 53(10): 211 - 219.
FENG Hao, YANG Zhenting, CHEN Hao, et al. Estimation of summer maize SPAD based on UAV multispectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(10): 211 - 219. (in Chinese)
[29] 程千, 徐洪刚, 曹引波,等. 基于无人机多时相植被指数的冬小麦产量估测[J]. 农业机械学报, 2021, 52(3): 160 - 167.
CHENG Qian, XU Honggang, CAO Yinbo, et al. Grain yield prediction of winter wheat using multi-temporal UAV based on multispectral vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 160 - 167. (in Chinese)
[30] 韩文霆, 崔家伟, 崔欣,等. 基于特征优选与机器学习的农田土壤含盐量估算研究[J]. 农业机械学报, 2023, 54(3): 328 - 337.
HAN Wenting, CUI Jiawei, CUI Xin, et al. Estimation of farmland soil salinity content based on feature optimization and machine learning algorithms[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 328 - 337. (in Chinese)
[31] 韦春宇, 杜娅丹, 程智楷,等. 基于无人机遥感植被指数优选的覆膜冬小麦估产研究[J]. 农业机械学报,2024,55(4): 146 - 154,175.
WEI Chunyu, DU Yadan, CHENG Zhikai, et al. Yield estimation of mulched winter wheat based on UAV remote sensing optimized by vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(4):146 - 154, 175. (in Chinese)
[32] 韩建文, 冯春晖, 彭杰,等. 不同分辨率无人机多光谱影像的棉花叶面积指数估测研究[J]. 棉花学报, 2022, 34(4): 338 - 349.
HAN Jianwen, FENG Chunhui, PENG Jie, et al. Estimation of leaf area index of cotton from unmanned aerial vehicle multispectral images with different resolutions[J]. Cotton Science, 2022, 34(4): 338 - 349. (in Chinese)
[33] CHENG Z, GU X, ZHOU Z, et al. Enhancing in-season yield forecast accuracy for film-mulched wheat: a hybrid approach coupling crop model and UAV remote-sensing data by ensemble learning technique[J]. European Journal of Agronomy, 2024, 156:127174.
[34] ZOU M, LIU Y, FU M, et al. Combining spectral and texture feature of UAV image with plant height to improve LAI estimation of winter wheat at jointing stage[J]. Frontiers in Plant Science, 2024, 14: 1272049.