

基于采样点光谱信息窗口尺度优化的土壤含水率 无人机多光谱遥感反演

靳亚红^{1,2} 吴鑫淼^{1,2} 甄文超^{2,3} 崔晓彤^{1,2} 陈丽⁴ 郅志红^{1,2}

(1. 河北农业大学城乡建设学院, 保定 071001; 2. 农业农村部华北节水农业重点实验室, 保定 071001;

3. 河北农业大学农学院, 保定 071001; 4. 保定市灌溉试验站, 保定 071000)

摘要: 针对空间异质性导致的土壤含水率反演误差较大的问题, 分别以玉米灌浆期和小麦苗期的土壤含水率反演为例, 利用无人机多光谱遥感技术获取喷灌和畦灌灌溉方式下的正射影像。将 34 组光谱特征变量按照滑动窗口法提取不同空间尺度的光谱信息平均值, 通过极端梯度提升 (Extreme gradient boosting, XGBoost)、支持向量机回归 (Support vector machine regression, SVR) 以及偏最小二乘回归 (Partial least squares regression, PLSR) 3 种机器学习模型确定采样点光谱信息最优窗口尺度; 然后, 采用皮尔逊相关系数特征变量筛选法 (Pearson correlation coefficient feature variable screening method, R) 结合 XGBoost 和 SVR 模型对提取的 34 组光谱特征变量进行筛选, 选取与土壤含水率敏感的特征变量; 最后, 估算土壤含水率。结果表明: 喷灌方式下所选择的采样点最优光谱信息窗口尺度比畦灌小, 其最优窗口尺度范围分别为 $11 \times 11 \sim 21 \times 21$ 和 $15 \times 15 \sim 29 \times 29$; 采用皮尔逊相关系数特征变量筛选方法结合机器学习模型可有效提高土壤含水率反演精度; 5 种机器学习模型 (R_XGBoost、R_SVR、XGBoost、SVR、PLSR) 中 R_XGBoost 模型估算土壤含水率精度最优, 在喷灌和畦灌方式下玉米灌浆期 R_XGBoost 模型的测试集决定系数 R^2 分别为 0.80、0.83, 均方根误差 (Root mean square error, RMSE) 分别为 1.27% 和 0.98%, 小麦苗期 R^2 分别为 0.76、0.79, RMSE 分别为 1.68% 和 0.85%; 土壤含水率反演模型在畦灌条件下的精度优于喷灌条件下。该研究可为基于无人机多光谱影像分析的信息挖掘和土壤水分监测提供参考。

关键词: 土壤含水率; 窗口尺度; 无人机多光谱遥感; 机器学习; 特征变量; 反演

中图分类号: S152.7; TP79

文献标识码: A

文章编号: 1000-1298(2024)01-0316-12

OSID:



UAV Multispectral Remote Sensing Inversion of Soil Moisture Content Based on Window Size Optimization of Spectral Information at Sampling Points

JIN Yahong^{1,2} WU Xinmiao^{1,2} ZHEN Wenchao^{2,3} CUI Xiaotong^{1,2} CHEN Li⁴ QIE Zhihong^{1,2}

(1. College of Urban and Rural Construction, Hebei Agricultural University, Baoding 071001, China

2. Key Laboratory of Water Saving Agriculture in North China, Ministry of Agriculture and Rural Affairs, Baoding 071001, China

3. College of Agronomy, Hebei Agricultural University, Baoding 071001, China

4. Baoding Irrigation Experimental Station, Baoding 071000, China)

Abstract: The primary factor in crop growth and one of the fundamental indicators used to monitor the wetness of fields is soil moisture. The relationship between the size of spectral information window of sampling points and soil moisture was mainly studied to solve the problem of soil moisture inversion error caused by spatial heterogeneity. UAV remote sensing technology was utilized to acquire multispectral orthophoto images during the corn filling and wheat seedling stages, under both sprinkler irrigation and border irrigation. Initially, the sliding window method was employed to extract 34 groups of spectral characteristic variables, capturing the average spectral information across various spatial scales. Subsequently, the optimal window size of spectral information at the sampling points was determined by using three machine learning models: extreme gradient Boost (XGBoost), support vector machine regression (SVR), and partial least squares regression (PLSR). Next, the feature variables extracted

收稿日期: 2023-08-29 修回日期: 2023-10-13

基金项目: 河北省重点研发计划项目 (22327002D、21327001D) 和国家重点研发计划项目 (2018YFD0300503-15)

作者简介: 靳亚红 (1996—), 女, 博士生, 主要从事节水灌溉理论与新技术研究, E-mail: hhy718509@163.com

通信作者: 郅志红 (1969—), 男, 教授, 博士生导师, 主要从事节水灌溉理论与新技术研究, E-mail: qiezhong@163.com

the 34 groups of spectral features were screened by using the Pearson correlation coefficient feature variable screening method (R) in conjunction with the XGBoost and SVR machine learning models. Subsequently, the feature variables that demonstrated sensitivity to soil water were selected. Lastly, the estimation of soil moisture was conducted. The results indicated that the optimal spectral information window for sampling points under sprinkler irrigation was smaller compared with that under border irrigation. Specifically, the optimal window size for sprinkler irrigation was ranged from 11×11 to 21×21 , while for border irrigation, it was ranged from 15×15 to 29×29 . The eigenvariable screening method, employing the Pearson correlation coefficient in combination with machine learning models, can significantly enhance the accuracy of soil moisture inversion. Among the five machine learning models (R_XGBoost, R_SVR, XGBoost, SVR, PLSR), the R_XGBoost model exhibited the highest accuracy in estimating soil moisture. The R_XGBoost model achieved R^2 values of 0.80 and 0.83, and RMSE values of 1.27% and 0.98% under spray irrigation and border irrigation, respectively. Additionally, the R^2 values were 0.76 and 0.79, and the RMSE values were 1.68% and 0.85%, respectively. The accuracy of the soil water inversion models was higher under border irrigation compared with that of sprinkler irrigation. The research result can serve as a valuable reference for information mining and soil moisture monitoring through the analysis of UAV multi-spectral images.

Key words: soil moisture; window size; UAV multi-spectral remote sensing; machine learning; features variables; inversion

0 引言

土壤含水率是地表与大气之间水文循环和能量交换的关键参数,对旱情监测、灌溉决策及农作物生长状况评价等具有指导性作用^[1]。其在空间分布上有着较强的差异性,并随着时间的变化而发生相应改变,故及时准确评估土壤水分状况对于旱情评估及灌溉管理具有重要意义。传统的单点测量方法难以有效获得大规模的土壤水分信息以反映全貌^[2],在受到土壤质地、植被、地形地貌、降雨、灌溉及人类活动等非线性因子的影响下^[3],若测点代表性较差,则反映全域的动态监测能力就较低^[4]。近年来,遥感因其具有高效便捷、及时、无损、可进行大范围监测等优势,逐渐被认为是估算地表土壤水分的先进手段^[5-6]。但在利用遥感图像进行解析时,往往忽略了地物的尺度、形状、纹理等空间特征信息,且没有考虑临近像素地物的空间自相关性这一基本地学定律^[7]。因此,确定采样点最佳的遥感信息尺度及建立模拟土壤水分精准监测的数学模型已成为精准农业中的一个重要研究方向。

国内外学者采用遥感技术对监测土壤水分开展了一系列的研究,并证明了该技术的可行性。张智韬等^[8-9]使用土壤光谱反射率估测土壤含水率时,发现蓝光波段(490 nm)和近红外波段(800 nm)反射率与土壤含水率相关性较为显著,近红外波段(900 nm)反射率与土壤含水率相关性不显著,后续又针对植被覆盖区的土壤水分光谱信息进行研究,发现在众多植被指数中归一化绿红差异指数(NGRDI)与表层土壤含水率相关性最高,反演效果

最佳;BORGOGNO-MONDINO 等^[10]通过研究发现,归一化植被指数(NDVI)和归一化差异水分指数(NDWI)在估测葡萄园土壤含水率方面具有较大的潜力,适用于土壤水分状况的季节性描述。除此之外,增强型植被指数(EVI)、归一化干旱指数(NDDI)及土壤调整植被指数(SAVI),也已被用于土壤水分变化的监测中^[11-12]。但土壤含水率与光谱之间有时可能存在非线性、异方差及多共线性等复杂关系^[13]。为解决这些问题,MU 等^[14]对数据进行充分挖掘,提出了一种新的非线性神经网络方法,建立了基于高分辨率、高光谱和微波多源遥感数据的土壤含水率估算模型,与线性模型的估计结果相比精度有所提高,均方根误差(RMSE)下降 16.44%。ADAB 等^[15]对不同土地利用类型的土壤水分进行估测研究,发现随机森林比支持向量机回归(Support vector machine regression,SVR)、人工神经网络和弹性网络回归算法构建的土壤含水率模型更为准确,但模型的适用情况还有待研究。总体而言,不同模型及方法的影响因素较多、差别较大,同时对研究区域的适用条件也不尽相同。因此,筛选合适的土壤水分模型对精准预测具有决定性作用。

随着研究者对数据时效性、成本性及准确性等目标的更高要求,无人机遥感监测技术已经成为开展参数反演研究的前沿手段,而从遥感角度出发的地学描述所存在的多尺度问题,也逐渐成为遥感定量化描述的首要问题^[16]。赵晓庆等^[17]采用无人机搭载的高光谱数据对大豆产量估测时发现,光谱空间尺度影响产量估算精度,并确定光谱空间范围长、宽与小区总长、宽之间的比例为 4.25 : 5 ~

4.5:5 时,为大豆产量估算的最优遥感影像范围。DENG 等^[18]对猕猴桃果园的土壤水分进行采样窗口分析时,发现选择实地面积为 2.412 m²所对应的光谱空间能够较好地反演果园土壤水分情况。由于无人机影像能够包含其研究区域的所有光谱信息^[17],在空间异质性以及边界像元的影响下,过大或过小的取样空间尺度,均会影响土壤水分的估算精度,同时相关研究也表明不同的灌溉工程型式对土壤水分分布及均匀度也具有一定的影响^[19],比如:畦灌条件下主要表现为沿畦田长度方向上的水分差异^[20],而喷灌条件下的水分分布主要受喷头喷洒范围内的径向分布差异以及喷头组合形式、组合间距的影响^[21]。因此,有必要基于无人机多光谱影像数据,明确不同灌溉方式下的土壤水分采样点影像空间最优尺度,以及探讨其在不同机器学习方法下的土壤水分估算效果。

综上,本文以喷灌和畦灌 2 种灌溉方式为研究对象,利用极端梯度提升(Extreme gradient boosting, XGBoost)、支持向量机回归及偏最小二乘回归

(Partial least squares regression, PLSR)等方法构建作物不同生育期采样点光谱信息窗口的土壤水分反演模型,以期确定喷灌和畦灌 2 种灌溉方式的采样点光谱最优空间尺度;在此基础上,采用皮尔逊相关系数特征选择算法分别结合 2 种机器学习模型(XGBoost、SVR)对 34 组光谱特征变量进行筛选预测指标;评估在有无特征变量筛选下的 XGBoost、SVR 以及 PLSR 回归模型反演土壤含水率的适用性,并定量分析 5 种回归模型估算土壤含水率的精度差异。

1 材料与方 法

1.1 研究区概况

研究区域位于河北省山前平原保定市望都县望都镇(115°06'56"E,38°42'07"N,海拔 42 m),如图 1 所示。研究区属于典型暖温带大陆性季风气候。其中试验地面积为 1.72 hm²,土壤类型为砂壤土,土壤容重为 1.58 g/cm³。年平均气温 11.8℃,年平均降雨量约为 508.9 mm,多年平均蒸发量 1 709.56 mm,年平均日照时数 2 677.8 h,无霜期 189 d。




图 1 研究区示意图
Fig.1 Schematic of study area

试验地共设置喷灌和畦灌 2 种处理,分别为可调角度摇臂式喷头进行灌溉和畦田灌溉。试验区主要种植模式为麦玉米轮作,2022 年小麦种植品种为“马兰 1 号”,玉米种植品种为“郑丹 958”。

1.2 数据采集与处理

1.2.1 无人机多光谱数据采集

采用大疆创新公司(DJI)生产的精灵 4 四旋翼无人机搭载多光谱传感器进行遥感影像数据采集,其中包括 1 个可见光相机通道以及 5 个用于多光谱成像的单色通道(波长分别为 450 nm(蓝,B)、560 nm(绿,G)、650 nm(红,R)、730 nm(红边,RE)、840 nm(近红外,NIR)),并配有辐射定标漫反射板(95%反射参考目标)进行影像的辐射校正。多光

谱影像采集时间为 2022 年 9 月 6 日和 10 月 17 日的 11:00—15:00,其中前一次采集为玉米灌浆期,后一次采集为小麦苗期。2 次采集均在晴朗无风情况下进行,每次采用固定航线飞行,同时设置多光谱相机镜头垂直向下,飞行高度 50 m,飞行速度 5 m/s,航向重叠率和旁向重叠率分别设置为 80%和 70%,地面分辨率为 3 cm/像素。

1.2.2 植被指数提取

遥感影像采集结束后利用 Pix4DMapper 软件对其进行辐射校正、拼接、合成,得到试验区的正射影像。并采用 Python 2.7 的“Arcpy”库对影像进行研究区裁剪、波段计算,Python 3.9 的“Gdal”库以滑动窗口的方法提取以采样点为中心的 1×1~81×81

窗口内像素的平均值。基于无人机多光谱图像的波段范围,本文共涉及 5 个单波段反射率和 29 种植被

指数,共计 34 个特征变量,其植被指数计算方法如表 1 所示。

表 1 植被指数汇总

Tab.1 Vegetation index summary

名称	计算公式	文献序号
归一化植被指数 (NDVI)	$NDVI = (NIR - R) / (NIR + R)$	[22]
植被覆盖度 (FV)	$FV = (NDVI - NDVI_{soil}) / (NDVI_{veg} - NDVI_{soil})$	[23]
地表比辐射率 (Dibiaobi)	$Dibiaobi = 0.004FV + 0.986$	[24]
比值植被指数 1 (RVI1)	$RVI_1 = NIR / R$	[25]
改进比值植被指数 (MSR)	$MSR = (NIR / R - 1) / (\sqrt{NIR / R} + 1)$	[26]
土壤调整植被指数 (SAVI)	$SAVI = 1.5 (NIR - R) / (NIR + R + 0.5)$	[27]
修改型土壤调整植被指数 (MSAVI)	$MSAVI = [2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}] / 2$	[28]
优化土壤调节植被指数 (OSAVI)	$OSAVI = (NIR - R) / (NIR + R + 0.16)$	[29]
重归一化植被指数 (RDVI)	$RDVI = (NIR - R) / \sqrt{NIR + R}$	[30]
权重差异植被指数 (WDVI)	$WDVI = NIR - 1.06R$	[25]
差值植被指数 (DVI)	$DVI = NIR - R$	[31]
红外百分比植被指数 (IPVI)	$IPVI = NIR / (NIR + R)$	[32]
简单比值色素指数 (SRPI)	$SRPI = B / R$	[33]
归一化绿红差异指数 (NGRDI)	$NGRDI = (G - R) / (G + R)$	[34]
绿度指数 (GI)	$GI = G / R$	[35]
三角形植被指数 (TVI)	$TVI = 60(NIR - G) - 100(R - G)$	[36]
归一化差异水分指数 (NDWI)	$NDWI = (G - NIR) / (G + NIR)$	[37]
归一化干旱指数 (NDDI)	$NDDI = (NDVI - NDWI) / (NDVI + NDWI)$	[38]
绿色归一化植被指数 (GNDVI)	$GNDVI = (NIR - G) / (NIR + G)$	[39]
比值植被指数 2 (RVI2)	$RVI_2 = NIR / G$	[40]
绿色叶绿素指数 (CI)	$CI = NIR / G - 1$	[25]
归一化色素叶绿素指数 (NPCI)	$NPCI = (R - B) / (R + B)$	[41]
绿叶指数 (GLI)	$GLI = (2G - R - B) / (2G + R + B)$	[42]
绿色光谱指数 (EXG)	$EXG = 2G - R - B$	[43]
抗大气指数 (VARI)	$VARI = (G - R) / (G + R - B)$	[44]
增强型植被指数 (EVI)	$EVI = 2.5 (NIR - R) / (NIR + 6R - 7.5B + 1)$	[22]
植被衰减指数 (PSRI)	$PSRI = (R - G) / RE$	[45]
改进叶绿素吸收指数 (MCARI)	$MCARI = [RE - R - 0.2(RE - G)] RE / R$	[46]
转换叶绿素吸收指数 (TCARI)	$TCARI = 3[RE - R - 0.2(RE - G) RE / R]$	[46]

1.2.3 地面数据采集与处理

在每次无人机多光谱数据采集完成后,采用网格随机布点的方法,使用土钻在固定点位进行取土,同时记录各采样点的 GPS 信息。设计取土深度为表层 0 ~ 20 cm,采集完毕后将其土样充分混合,称量,之后严格按照试验规范用原位土回填土壤孔洞。每次在喷灌试验田采集 120 个采样点,畦灌试验田采集 119 个采样点,并保证相邻两点间的距离大于 3 m,最后用干燥法测定土壤含水率。

1.3 皮尔逊相关系数

皮尔逊相关系数 (Pearson, r) 表示特征变量与目标变量之间的线性相关性,取值范围为 $[-1, 1]$, r 绝对值越大,表示两个变量间的线性相关程度越强。

1.4 机器学习算法

1.4.1 极端梯度提升模型

极端梯度提升模型 (XGBoost) 是在梯度下降树

(Gradient boosting decision tree, GBDT) 算法的基础上对损失函数进行二阶泰勒展开,最大的特点是能够通过并行学习实现加速计算,同时在目标函数上加以改进来提高预测精度^[47]。首先使用训练集构建一棵初始树进行模型训练,得到模型预测值与实际值的残差;然后每次迭代过程中都增加一棵树来拟合模型上次预测的残差,直至模型学习进程被终止,由此形成由众多树模型集成的迭代残差树集合。本研究采用交叉验证和 Optuna 超参数寻优相结合的方法对其进行参数搜寻。XGBoost 模型的训练和测试通过 Python 软件完成。

1.4.2 支持向量机回归模型

支持向量机回归模型 (SVR) 是基于统计学理论,遵循结构风险最小化原理,通过引入适当的内积核函数将空间中的样本映射到高维特征空间中,在该空间中对数据进行线性回归处理^[48]。常用的核

函数有线性核函数 (Linear)、多项式核函数 (Polynomial)、径向基核函数 (RBF)、Sigmoid 核函数 (Sigmoid)。本研究采用径向基核函数 (RBF) 进行计算,采用交叉验证和 Optuna 超参数寻优相结合的方法对参数进行选择和调整。SVR 模型的训练和测试通过 Python 软件完成。

1.4.3 偏最小二乘回归模型

偏最小二乘回归模型 (PLSR) 是一种基于多元线性回归分析、典型相关分析和主成分分析为一体的回归模型。针对自变量存在严重多重相关性的问题,将原始自变量转换为一组新的潜在变量,然后通过主成分进行回归分析,从而达到在一定程度上减少自变量之间的共线性,提高模型的预测能力的目的。本研究通过交叉验证的最小均方根误差来进行潜在变量最优数量选择^[49]。PLSR 模型的训练和测试通过 Python 软件完成。

1.5 模型精度评价

采用决定系数 (Coefficient of determination, R^2) 和均方根误差 (Root mean square error, RMSE) 对模型的训练集和测试集精度进行评价。 R^2 越大, RMSE 越小,说明模型精度越高,预测能力越强。

2 结果与分析

2.1 土壤含水率描述性统计分析

图 2 为作物不同生育期喷灌和畦灌灌溉方式下的土壤含水率全集样本、训练集样本和测试集样本的描述性统计分析结果。从图 2 可知,在玉米灌浆期喷灌和畦灌条件下土壤含水率全集样本平均值分别为 16.87%、17.14%,标准差为 2.70%、2.44%,

训练集样本 (84 个) 和测试集样本 (36 个) 均值分别为 16.95%、16.71% 和 17.27%、16.83%;在小麦苗期喷灌和畦灌条件下土壤含水率全集样本平均值分别为 14.84%、16.99%,标准差为 3.57%、2.17%,训练集样本 (83 个) 和测试集样本 (36 个) 均值分别为 15.44%、13.45% 和 16.95%、17.09%;其中畦灌条件下土壤含水率大于喷灌条件。根据变异系数 C_v 等级 ($C_v < 10\%$ 为弱变异, $10\% \leq C_v \leq 100\%$ 为中等变异, $C_v > 100\%$ 为强变异) 划分标准可知,玉米灌浆期喷灌和畦灌灌溉方式下土壤含水率变异系数分别为 16.00%、14.24%,在小麦苗期喷灌和畦灌灌溉方式下土壤含水率变异系数分别为 24.06%、12.77%,说明植被覆盖程度对土壤水分的空间变异性有一定影响,且喷灌条件下土壤水分变异性大于畦灌条件下土壤水分变异性。

2.2 采样点光谱信息的最佳窗口分析

图 3 为作物不同生育期喷灌和畦灌灌溉方式下采样点光谱信息窗口尺度与不同机器学习模型评价指标 R^2 和 RMSE 的关系。随着采样点光谱信息窗口尺度的增大, R^2 呈先增大后减小的趋势, RMSE 呈先减小后增大的趋势。在喷灌灌溉方式下,玉米灌浆期土壤含水率反演的 XGBoost 模型 R^2 介于 0.14 ~ 0.79 之间, RMSE 介于 1.30% ~ 2.66% 之间; SVR 模型 R^2 介于 0.21 ~ 0.76 之间, RMSE 介于 1.42% ~ 2.55% 之间; PLSR 模型 R^2 介于 0.24 ~ 0.72 之间, RMSE 介于 1.51% ~ 2.50% 之间;同时,在喷灌条件下,小麦苗期与玉米灌浆期所采用的 3 种模型均表现出在窗口尺度为 1×1 时, R^2 达到较小水平, RMSE 达到较大水平;在窗口尺度为 15×15




图 2 土壤含水率描述性统计特征

Fig.2 Descriptive statistics characteristics of soil moisture content




图 3 模型 R^2 和 RMSE 与窗口尺度的关系

Fig. 3 Relationship between R^2 and RMSE and sampling window size

时, R^2 达到较大值, RMSE 达到较小值; 通过对喷灌灌溉条件下玉米灌浆期及小麦苗期的土壤含水率反演模型精度评价指标可知, 在 $11 \times 11 \sim 21 \times 21$ 窗口尺度范围, 土壤含水率反演所采用的 XGBoost、SVR 及 PLSR 模型的精度评价指标均表现出 R^2 大于 0.60 的趋势, 表明各模型在此范围内反演土壤含水率能力较强, 模型预测能力较好。

在畦灌灌溉方式下, 玉米灌浆期土壤含水率反演 XGBoost 模型 R^2 介于 0.39 ~ 0.83 之间, R^2 最大值 (0.83) 在窗口尺度为 21×21 处理, R^2 最小值

(0.39) 在窗口尺度为 65×65 处理, RMSE 介于 0.99% ~ 1.86% 之间, RMSE 最小值 (0.99%) 在窗口尺度为 21×21 处理, RMSE 最大值 (1.86%) 在窗口尺度为 65×65 处理; SVR 模型 R^2 介于 0.39 ~ 0.78 之间, R^2 最大值 (0.78) 在窗口尺度为 21×21 处理, R^2 最小值 (0.39) 在窗口尺度为 1×1 及 3×3 处理, RMSE 介于 1.11% ~ 1.85% 之间, RMSE 最小值 (1.11%) 在窗口尺度为 21×21 处理, RMSE 最大值 (1.85%) 在窗口尺度为 1×1 及 3×3 处理; PLSR 模型 R^2 介于 0.15 ~ 0.74 之间, R^2 最大值

(0.74) 在窗口尺度为 17×17 处理, R^2 最小值 (0.15) 在窗口尺度为 1×1 处理, RMSE 介于 1.21% ~ 2.19% 之间, RMSE 最小值 (1.21%) 在窗口尺度为 17×17 处理, RMSE 最大值 (2.19%) 在窗口尺度为 1×1 处理。在小麦苗期采样点光谱信息窗口尺度为 21×21 处理时, XGBoost 与 SVR 模型的 R^2 达到最大, RMSE 达到最小。但 PLSR 模型的最好表现能力出现在窗口尺度 25×25 内, 在窗口尺度 21×21 上 PLSR 模型的精度位居所有窗口构建模型的第 4 水平。在畦灌条件下选择窗口尺度范围为 $15 \times 15 \sim 29 \times 29$ 作为较优的影像空间尺度, 能够有效减少土壤含水率信息的缺失以及避免采样点窗口边缘光谱的影响。

2.3 皮尔逊相关系数特征变量选择

为提高回归预测模型的精度, 采用 Python 3.9 的“Sklearn”库对特征变量数据进行 Standard Scaler 标准化处理, 并采用皮尔逊相关系数特征选择算法对 34 组特征光谱信息进行变量选择, 评估器分别为

XGBoost 和 SVR。其中 r 绝对值越高表示预测变量与目标变量的线性相关性越强, 根据皮尔逊相关系数评价程度指标 ($|r| \geq 0.8$ 时, 两变量间高度相关; $0.5 \leq |r| < 0.8$, 两变量中度相关; $0.2 \leq |r| < 0.5$, 两变量低度相关; $|r| < 0.2$, 两变量基本不相关), 采用皮尔逊相关系数特征选择算法从 $|r| \geq 0.2$ 的预测变量进行选择, 选取估算模型的 RMSE 最小为最终的预测变量, 进行土壤含水率反演。表 2 为采用皮尔逊相关系数特征选择算法 (R) 选取的作物不同生育期喷灌和畦灌灌溉方式下的最优特征变量组合。从表 2 可知, SVR 模型相较于 XGBoost 模型的特征变量选择个数处于较高水平。其中玉米灌浆期, 各模型所选用的公共特征变量为 NGRDI、TCARI、Dibiaobi、NDVI、IPVI、OASVI; 小麦苗期, 各模型所选用的公共特征变量为 GLI、SRPI、NDDI、TVI; 说明不同时期土壤含水率的敏感变量不同, 通过选择合适的特征变量进行模型构建, 能够提高回归模型的表现能力。

表 2 皮尔逊相关系数特征变量选择结果
Tab.2 Pearson correlation coefficient feature variable selection result

作物生育期	灌溉方式	机器学习模型	特征变量选择数量	最优特征变量组合
玉米灌浆期	喷灌	XGBoost	9	NGRDI、TCARI、Dibiaobi、NDVI、IPVI、RVI、OASVI、EVI、TVI
		SVR	23	NGRDI、TCARI、GI、FV、Dibiaobi、NDVI、IPVI、MSR、RVI、VARI、GNDVI、NDWI、CI、RVI2、MCARI、OASVI、RDVI、MSAVI、SAVI、EVI、GLI、SRPI、PSRI
	畦灌	XGBoost	11	NGRDI、Dibiaobi、IPVI、NDVI、TCARI、GI、OASVI、CI、RVI2、MSAVI、WDVI
		SVR	22	NGRDI、Dibiaobi、FV、IPVI、NDVI、TCARI、MSRI、GI、VARI、RVI、GNDVI、OASVI、CI、RVI2、RDVI、PSRI、GLI、SAVI、TVI、MCARI、R、B
小麦苗期	喷灌	XGBoost	5	GLI、SRPI、NDDI、TVI、RDVI
		SVR	18	GLI、EXG、SRPI、NPCI、NDDI、RVI、MSR、Dibiaobi、FV、NDVI、IPVI、TVI、WDVI、TCARI、MCARI、PSRI、EVI、N
	畦灌	XGBoost	11	OSAVI、SAVI、NDDI、RVI2、CI、TVI、SRPI、NGRDI、EXG、PSRI、GLI
		SVR	26	OASVI、SAVI、RDVI、Dibiaobi、IPVI、NDVI、FV、MSR、RVI、NDDI、MSAVI、MCARI、GNDVI、NDWI、RVI2、CI、TVI、EVI、SRPI、NPCI、DVI、NGRDI、GI、EXG、GLI、B

2.4 土壤含水率反演模型精度评价

图 4 为作物不同生育期喷灌和畦灌灌溉方式下的土壤含水率反演模型精度评价结果。由图 4a、4b 可知, 玉米灌浆期, 5 种机器学习模型在喷灌和畦灌灌溉方式下的训练集 R^2 均不小于 0.76, RMSE 均不大于 1.28%, 模型训练集精度均处于较高水平。根据各模型测试集精度结果分析, 反演效果从高到低依次为 R_XGBoost (皮尔逊相关系数特征选择算法和机器学习模型组合形式, 以此类推)、XGBoost、R_SVR、SVR、PLSR。R_XGBoost 模型的预测结果最优, 在喷灌和畦灌灌溉方式下, R^2 分别达到 0.80 和 0.83, 比 XGBoost 模型提升 0.01 和 0; RMSE 为 1.27% 和 0.98%, 比 XGBoost 模型降低 0.03 个百分

点和 0.01 个百分点。且畦灌条件下的土壤含水率模型精度大于喷灌条件下的模型精度。综合而言, R_XGBoost 模型在玉米灌浆期更具有较好的优势。由图 4c、4d 可知, 小麦苗期, 喷灌和畦灌灌溉方式下的土壤含水率 PLSR 回归模型在测试集上精度较低, 相反, R_XGBoost 模型在测试集上精度较高。在喷灌和畦灌条件下, R_XGBoost 模型训练集 R^2 分别为 0.77 和 0.85, 测试集 R^2 分别为 0.76 和 0.79, 两者 R^2 均不小于 0.76, RMSE 分别为 1.68% 和 0.85%, 均在 2.00% 以下, 模型具有较好的反演土壤含水率的效果。表明在小麦苗期, 无论是喷灌还是畦灌灌溉方式 R_XGBoost 回归模型均具有较强的能力。




图 4 土壤含水率实测值与预测值比较

Fig. 4 Comparisons of measured and predicted soil moisture contents

同时通过玉米灌浆期和小麦苗期在喷灌和畦灌灌溉方式下的 XGBoost、SVR、PLSR、R_XGBoost 和 R_SVR 5 种模型预测值和实测值数据的散点图可知,在测试集中,5 种机器学习模型斜率均表现出接近于 1 的趋势,说明这些模型用于监测土壤含水率是可行的。且 XGBoost 模型明显优于 SVR 和 PLSR 模型,同时采用皮尔逊相关系数进行特征变量筛选

的模型预测能力高于未经过特征变量筛选的模型,说明当特征变量个数较少时,模型仍然具有较强的容错能力。

3 讨论

土壤含水率作为监测农田墒情、诊断作物水分胁迫状况以及指导精准灌溉的重要参数,其状态和

分布对土壤-植物-大气系统中的生态水文过程有着直接影响,同时在植物、大气等环境因素的调控下,土壤水分也会受到一定影响^[50],并表现出较强的时间尺度和空间尺度异质性。目前,众多研究者发现无人机遥感监测技术能够更好地满足农田尺度遥感信息定量化描述的基本要求,并构建了多种较优的模型,但在研究中所采用的模型通常是基于某一特定像元尺度上得出的,而遥感影像在不同的时间和空间上所包含的地表信息都具有极大的跨度,在不同尺度上所总结的规律可能具有相似性,也可能难以具有普适性^[51]。本文通过 3 种机器学习模型,探讨了不同灌溉方式下基于采样点光谱信息窗口尺度优选的土壤水分定量化描述。研究发现,在不同的光谱信息空间尺度上,3 种模型的精度评价指标 R^2 和 RMSE 均表现出相同的变化趋势,随着窗口尺度的逐渐增大, R^2 表现为先增大后减小趋势, RMSE 则表现为先减小后增大趋势。主要原因在于无人机遥感空间分辨率较高^[49],单一像元即代表纯净像元,当所获取的单一像元光谱信息为土壤信息、冠层信息以及目标阴影信息时,难以有效表达土壤含水率实际情况。即采样点光谱信息窗口尺度过小时,不能涵盖有效的光谱信息进而造成模型较大的随机误差。而当采样点光谱信息窗口尺度过大时,边界像元增加了光谱信息的冗余性,使模型精度降低。这与赵晓庆等^[17]研究无人机遥感影像空间尺度对大豆产量预测精度的影响结果一致。并且本文通过研究发现,喷灌方式下所得到的采样点光谱信息窗口尺度总体上比畦灌方式下所得到的采样点光谱信息窗口尺度小,主要原因在于喷灌方式下的土壤含水率空间异质性大于畦灌方式,以及在不同灌溉方式下地物本身的辐射特性造成遥感像元尺度的差异较大,最终导致了在非线性关系的作用下土壤含水率反演的结果不一致,这与刘良云^[52]针对叶面积指数遥感尺度效应与尺度纠正的观点一致。通过以上研究表明,首先明确采样点光谱信息窗口尺度,对构建土壤含水率精准监测模型具有较好的效果。

在采样点最优光谱信息窗口的条件下,本文构建了作物不同生育期喷灌和畦灌灌溉方式下的土壤含水率反演模型。结果表明, XGBoost、SVR、PLSR 3 种模型反演土壤含水率均具有较高的精度和鲁棒性,同样地,众多研究者通过 XGBoost^[53]、SVR^[54] 和 PLSR^[2] 对土壤含水率进行反演,结果表明,通过机器学习模型估算土壤含水率是可行的。且本文在此基础上利用特征变量筛选法结合机器学习方法构建不同的土壤含水率反演模型,研究发现采用皮尔逊

相关系数进行特征变量筛选的模型预测能力高于未经过特征变量筛选的模型。这与王思楠等^[2]的研究结果一致,其利用最优子集筛选变量的方法直接删除冗余特征,显著提高了预测模型精度。此外,本研究采用皮尔逊相关系数特征选择算法筛选出适用于 XGBoost、SVR 机器学习模型的公共变量 NGRDI、TCARI、Dibiaobi、NDVI、IPVI、OASVI(玉米灌浆期), GLI、SRPI、NDDI、TVI(小麦苗期),同时模型测试集 R^2 均不小于 0.76,这与张智韬等^[9]先剔除土壤背景,后采用 NGRDI 直接反演土壤含水率效果相同。本研究利用 5 种机器学习模型对土壤含水率进行了有效预测,结果表明,在相同条件下 XGBoost 模型效果优于 SVR 和 PLSR 模型。葛翔宇等^[53]通过无人机高光谱影像结合不同预处理、光谱指数和 XGBoost 模型估算土壤含水率 R^2 达到 0.926,比其他模型具有更好的预测结果,这与本研究结果一致。王梦迪等^[49]比较了 PLSR、SVR、人工神经网络、随机森林和 XGBoost 模型对农田土壤含水率的估算精度,其中 PLSR 表现优于 SVR 模型,但 PLSR 模型在本研究中的表现没有明显优于 SVR 模型。主要原因在于模型引入的预测变量不同^[2],以及在本研究中 SVR 模型能够通过较强的适应能力去处理数据的复杂性。同时,其他研究结果也具有相似的说明^[48,54]。

然而,本研究仍然存在诸多不足之处。首先,主要探讨了采样点光谱信息窗口尺度平均值对土壤含水率反演精度的影响,并未考虑剔除土壤背景后的光谱信息情况,后续的研究可通过划分土壤与植被像元阈值准确监测土壤水分情况;其次,仅采用皮尔逊相关系数一种特征变量筛选方法,并未与其他特征变量筛选方法进行比较,无法确定诸多影响土壤水分的敏感性光谱信息;最后,并未考虑天气、作物等因素对土壤水分的影响,因此对所构建的土壤含水率反演模型的稳定性及泛化能力还需进一步研究。

4 结 论

(1)通过对采样点光谱信息窗口尺度与土壤含水率监测模型精度进行分析,发现随着采样点光谱信息窗口尺度的增大,反演土壤含水率机器学习模型精度呈先增大后减小趋势。

(2)对比喷灌和畦灌灌溉方式下的最佳采样点光谱信息窗口尺度发现,喷灌条件下,在采样点光谱信息窗口尺度为 15×15 时, R^2 达到最大, RMSE 达到最小,优选窗口尺度 $11 \times 11 \sim 21 \times 21$ 对喷灌条件下的土壤含水率机器学习模型精度更高;畦灌条件

下,窗口尺度为 21×21 时,土壤含水率监测模型精度达到最优,且优选窗口尺度 $15 \times 15 \sim 29 \times 29$ 对畦灌条件下的土壤含水率机器学习模型精度更高。

(3)对作物不同生育期喷灌和畦灌灌溉方式下的土壤含水率机器学习模型进行比较,结果表明,基

于皮尔逊相关系数进行特征变量筛选的 R_XGBoost 模型精度高于 R_SVR、XGBoost、SVR、PLSR 4 种机器学习模型,且 R^2 在玉米灌浆期喷灌和畦灌方式下分别为 0.80、0.83,小麦苗期分别为 0.76、0.79。在畦灌条件下模型精度优于喷灌条件下。

参 考 文 献

[1] WANG J H, GE Y, HEUVELINK G, et al. Upscaling in situ soil moisture observations to pixel averages with spatio-temporal geostatistics[J]. Remote Sensing, 2015, 7(9): 11372 – 11388.

[2] 王思楠,李瑞平,吴英杰,等. 基于环境变量和机器学习的土壤含水率反演模型研究[J]. 农业机械学报,2022,53(5): 332 – 341.

WANG Sinan, LI Ruiping, WU Yingjie, et al. Soil moisture inversion based on environmental variables and machine learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 332 – 341. (in Chinese)

[3] 赵文举,李晓萍,范严伟,等. 西北旱区压砂地土壤含水率的时空分布特征[J]. 农业工程学报,2015,31(17):144 – 151.

ZHAO Wenju, LI Xiaoping, FAN Yanwei, et al. Spatial-temporal stability distribution characteristics of soil moisture in gravel-sand mulched field in northwestern arid area[J]. Transactions of the CSAE, 2015, 31(17): 144 – 151. (in Chinese)

[4] 赵伟,文凤平,蔡俊飞. 被动微波土壤含水率遥感产品空间降尺度研究:方法、进展及挑战[J]. 遥感学报,2022,26(9): 1699 – 1722.

ZHAO Wei, WEN Fengping, CAI Junfei. Methods, progresses, and challenges of passive microwave soil moisture spatial downscaling[J]. Journal of Remote Sensing, 2022, 26(9): 1699 – 1722. (in Chinese)

[5] RODRÍGUEZ-FERNÁNDEZ N, AL BITAR A, COLLIANDER A, et al. Soil moisture remote sensing across scales[J]. Remote Sensing, 2019, 11(2): 1 – 5.

[6] 吴泽棉,邱建秀,刘苏峡,等. 基于土壤含水率的农业干旱监测研究进展[J]. 地理科学进展,2020,39(10):1758 – 1769.

WU Zemian, QIU Jianxiu, LIU Suxia, et al. Advances in agricultural drought monitoring based on soil moisture[J]. Progress in Geography, 2020, 39(10): 1758 – 1769. (in Chinese)

[7] 刘良云,王纪华,赵春江,等. 基于地物空间信息的浮动先验概率最大似然分类研究[J]. 遥感学报,2006,10(2):227 – 235.

LIU Liangyun, WANG Jihua, ZHAO Chunjiang, et al. Study on floating prior probability MLC based on spatial features and local spatial autocorrelation[J]. Journal of Remote Sensing, 2006, 10(2): 227 – 235. (in Chinese)

[8] 张智韬,王海峰,韩文霆,等. 基于无人机多光谱遥感的土壤含水率反演研究[J]. 农业机械学报,2018,49(2):173 – 181.

ZHANG Zhitao, WANG Haifeng, HAN Wenting, et al. Inversion of soil moisture content based on multispectral remote sensing of UAVs[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 173 – 181. (in Chinese)

[9] 张智韬,周永财,杨帅,等. 剔除土壤背景的冬小麦根域土壤含水率遥感反演方法[J]. 农业机械学报,2021,52(4): 197 – 207.

ZHANG Zhitao, ZHOU Yongcai, YANG Shuai, et al. Inversion method for soil water content in winter wheat root zone with eliminating effect of soil background[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 197 – 207. (in Chinese)

[10] BORGOGNO-MONDINO E, NOVELLO V, LESSIOA A, et al. Describing the spatio-temporal variability of vines and soil by satellite-based spectral indices: a case study in Apulia (South Italy) [J]. International Journal of Applied Earth Observation and Geoinformation, 2018, 68: 42 – 50.

[11] PENG C M, DENG M X, DI L P. Relationships between remote-sensing-based agricultural drought indicators and root zone soil moisture: a comparative study of Iowa[J]. IEEE Journal of Selected Topics Applied Earth Observations and Remote Sensing, 2014, 7(11): 4572 – 4580.

[12] CASAMITJANA M, TORRES-MADRONERO M C, BERNAL-RIOBO J, et al. Soil moisture analysis by means of multispectral images according to land use and spatial resolution on andosols in the Colombian Andes[J]. Applied Sciences-Basel, 2020, 10(16):1 – 15.

[13] 田美玲,葛翔宇,丁建丽,等. 耦合机器学习和机载高光谱数据的土壤含水量估算[J]. 激光与光电子学进展,2020, 57(9):232 – 241.

TIAN Meiling, GE Xiangyu, DING Jianli, et al. Coupled machine learning and unmanned aerial vehicle based hyperspectral data for soil moisture content estimation[J]. Laser & Optoelectronics Progress, 2020, 57(9): 232 – 241. (in Chinese)

[14] MU T H, LIU G W, YANG X G, et al. Soil-moisture estimation based on multiple-source remote-sensing images[J]. Remote Sensing, 2023, 15(1): 1 – 22.

[15] ADAB H, MORBIDELLI R, SALTALIPPI C, et al. Machine learning to estimate surface soil moisture from remote sensing data[J]. Water, 2020, 12(11): 1 – 27.

[16] 李小文,赵红蕊,张颖,等. 全球变化与地表参数的定量遥感[J]. 地学前缘,2002,9(2):365 – 370.

LI Xiaowen, ZHAO Hongrui, ZHANG Hao, et al. Global change study and quantitative remote sensing for land surface

- parameters[J]. Earth Science Frontiers, 2002, 9(2): 365–370. (in Chinese)
- [17] 赵晓庆,杨贵军,刘建刚,等. 基于无人机载高光谱空间尺度优化的大豆育种产量估算[J]. 农业工程学报,2017, 33(1):110–116.
- ZHAO Xiaoqing, YANG Guijun, LIU Jiangang, et al. Estimation of soybean breeding yield based on optimization of spatial scale of UAV hyperspectral image[J]. Transactions of the CSAE, 2017, 33(1): 110–116. (in Chinese)
- [18] DENG J T, PAN S J, ZHOU M G, et al. Optimum sampling window size and vegetation index selection for low-altitude multispectral estimation of root soil moisture content for Xuxiang kiwifruit[J]. Agricultural Water Management, 2023, 282: 1–12.
- [19] 赵东彬,仵峰,宰松梅,等. 不同灌水方式下灌水均匀度评价[J]. 人民黄河,2011,33(3):76–78.
- ZHAO Dongbin, WU Feng, ZAI Songmei, et al. Evaluation of irrigation uniformity under different irrigation methods[J]. Yellow River, 2011, 33(3): 76–78. (in Chinese)
- [20] 李江,黄增健,李涛,等. 考虑初始含水率沿程不均匀分布的畦灌技术要素调控[J]. 农业机械学报,2023,54(8):320–329,370.
- LI Jiang, HUANG Zengjian, LI Tao, et al. Regulation of border irrigation technical elements considering condition of uneven initial soil moisture content along border[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 320–329,370. (in Chinese)
- [21] 王新坤,薛子龙,徐胜荣,等. 双喷嘴负压反馈射流喷头水力性能研究[J]. 农业机械学报,2019,50(11):278–284.
- WANG Xinkun, XUE Zilong, XU Shengrong, et al. Hydraulic performance of negative pressure feedback jet sprinkler with double nozzles[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 278–284. (in Chinese)
- [22] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sensing of Environment, 2002, 83(1–2): 195–213.
- [23] 何宝忠,丁建丽,张喆,等. 新疆植被覆盖度趋势演变实验性分析[J]. 地理学报,2016,71(11):1948–1966.
- HE Baozhong, DING Jianli, ZHANG Zhe, et al. Experimental analysis of spatial and temporal dynamics of fractional vegetation cover in Xinjiang[J]. Acta Geographica Sinica, 2016, 71(11): 1948–1966. (in Chinese)
- [24] 杜国明,刘文琦,于佳兴,等. 三江平原水旱田分布对遥感反演局地地表温度的影响[J]. 农业工程学报,2019,35(5): 259–267,320.
- DU Guoming, LIU Wenqi, YU Jiaxing, et al. Influence of paddy field and dry field distribution on local surface temperature by remote sensing inversion in Sanjiang Plain[J]. Transactions of the CSAE, 2019, 35(5): 259–267,320. (in Chinese)
- [25] 罗玲,毛德华,张柏,等. 基于 Landsat OLI 影像的典型湿地芦苇植被光能利用率遥感反演方法初探[J]. 武汉大学学报 (信息科学版),2020,45(4):524–533.
- LUO Ling, MAO Dehua, ZHANG Bai, et al. Remote sensing estimation for light use efficiency of *Phragmites australis* based on Landsat OLI over typical wetlands[J]. Geomatics and Information Science of Wuhan University, 2020, 45(4): 524–533. (in Chinese)
- [26] 李相,丁建丽. 基于实测高光谱指数与 HSI 影像指数的土壤含水量监测[J]. 农业工程学报,2015,31(19):68–75.
- LI Xiang, DING Jianli. Soil moisture monitoring based on measured hyperspectral index and HSI image index [J]. Transactions of the CSAE, 2015, 31(19): 68–75. (in Chinese)
- [27] HUETE A R. A soil-adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment, 1988, 25:295–309.
- [28] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing Environment, 1994, 48:119–126.
- [29] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. Remote Sensing of Environment, 1996, 55(2): 95–107.
- [30] ROUJEAN J L, BREON F M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements [J]. Remote Sensing Environment, 1995, 51: 375–384.
- [31] 鲁向晖,杨宝城,张海娜,等. 基于无人机多光谱遥感的矮林芳樟叶片精油产量反演[J]. 农业机械学报,2023,54(4): 191–197,213.
- LU Xianghui, YANG Baocheng, ZHANG Haina, et al. Inversion of leaf essential oil yield of *Cinnamomum camphora* based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 191–197,213. (in Chinese)
- [32] CRIPPEN R E. Calculating the vegetation index faster[J]. Remote Sensing of Environment, 1990, 34(1):71–73.
- [33] PENUELAS J, BARET F, FILELLA I. Semi-empirical indices to assess carotenoids/chlorophyll A ratio from leaf spectral reflectance[J]. Photosynthetica, 1995, 31(2): 221–230.
- [34] HUNT E R, CAVIGELLI M, DAUGHTRY C S T, et al. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status[J]. Precision Agriculture, 2005, 6(4):359–378.
- [35] ZARCO-TEJADA P J, BERJÓN A, LÓPEZ-LOZANO R, et al. Assessing vineyard condition with hyperspectral indices: leaf and canopy reflectance simulation in a row-structured discontinuous canopy [J]. Remote Sensing of Environment, 2005, 99(3): 271–287.

[36] BROGE N H, LEBLANC E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density[J]. Remote Sensing of Environment, 2001, 76(2): 156 – 172.

[37] MCFEETERS S K. The use of the normalized difference water index (NDWI) in the delineation of open water features[J]. International Journal of Remote Sensing, 1996, 17(7): 1425 – 1432.

[38] 白开旭,刘朝顺,施润和,等. 2010 年中国西南旱情的时空特征分析——基于 MODIS 数据归一化干旱指数[J]. 地球信息科学学报,2012,14(1):32 – 40,48.
BAI Kaixu, LIU Zhaoshun, SHI Runhe, et al. Analysis of spatio-temporal characteristics of drought in Southwest China in 2010 by using MODIS—based normalized difference drought index[J]. Journal of Geo-Information Science, 2012, 14(1): 32 – 40,48. (in Chinese)

[39] WANG F M, HUANG J F, TANG Y L, et al. New vegetation index and its application in estimating leaf area index of rice [J]. Rice Science, 2007, 14(3): 195 – 203.

[40] XUE L H, CAO W X, LUO W H, et al. Monitoring leaf nitrogen status in rice with canopy spectral reflectance[J]. Agronomy Journal, 2004, 96(1): 135 – 142.

[41] RANJAN R, CHOPRA U K, SAHOO R N, et al. Assessment of plant nitrogen stress in wheat (*Triticum aestivum* L.) through hyperspectral indices[J]. International Journal of Remote Sensing, 2012, 33(20): 6342 – 6360.

[42] LUOHAICHI M, BORMAN M M, JOHNSON D E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat[J]. Geocarto International, 2001, 16(1): 65 – 70.

[43] SCHIRRMANN M, GIEBEL A, GLEINIGER F, et al. Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery[J]. Remote Sensing, 2016, 8(9): 1 – 19.

[44] SCHNEIDER P, ROBERTS D A, KYRIAKIDIS P C. A VARI-based relative greenness from MODIS data for computing the fire potential index[J]. Remote Sensing of Environment, 2008, 112(3): 1151 – 1167.

[45] SIMS D A, GAMON J A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages[J]. Remote Sensing of Environment, 2002, 81(2 – 3): 337 – 354.

[46] HABOUDANE D, MILLER J R, TREMBLAY N, et al. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture[J]. Remote Sensing of Environment, 2002, 81(2): 416 – 426.

[47] 夏晨真,姜艳艳,张星宇,等. 基于无人机高光谱影像的黑土区玉米农田土壤有机质估算[J]. 光谱学与光谱分析, 2023,43(8):2617 – 2626.
XIA Chenzhen, JIANG Yanyan, ZHANG Xingyu, et al. Estimation of soil organic matter in maize field of black soil area based on UAV hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2023, 43(8): 2617 – 2626. (in Chinese)

[48] 张智韬,谭丞轩,许崇豪,等. 基于无人机多光谱遥感的玉米根域土壤含水率研究[J]. 农业机械学报,2019,50(7): 246 – 257.
ZHANG Zhitao, TAN Chengxuan, XU Chonghao, et al. Retrieving soil moisture content in field maize root zone based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 246 – 257. (in Chinese)

[49] 王梦迪,何莉,刘潜,等. 基于小麦冠层无人机高光谱影像的农田土壤含水率估算[J]. 农业工程学报,2023,39(6): 120 – 129.
WANG Mengdi, HE Li, LIU Qian, et al. Estimating soil moisture contents of farmland using UAV hyperspectral images of wheat canopy[J]. Transactions of the CSAE, 2023, 39(6): 120 – 129. (in Chinese)

[50] WANG C, FU B J, ZHANG L, et al. Soil moisture-plant interactions: an ecohydrological review[J]. Journal of Soils and Sediments, 2019, 19(1): 1 – 9.

[51] 苏理宏,李小文,黄裕霞. 遥感尺度问题研究进展[J]. 地球科学进展,2001(4):544 – 548.
SU Lihong, LI Xiaowen, HUANG Yuxia. An review on scale in remote sensing[J]. Advance in Earth Sciences, 2001(4): 544 – 548. (in Chinese)

[52] 刘良云. 叶面积指数遥感尺度效应与尺度纠正[J]. 遥感学报,2014,18(6):1158 – 1168.
LIU Liangyun. Simulation and correction of spatialsclating effects for leaf area index[J]. Journal of Remote Sensing, 2014, 18(6): 1158 – 1168. (in Chinese)

[53] 葛翔宇,丁建丽,王敬哲,等. 一种基于无人机高光谱影像的土壤墒情检测新方法[J]. 光谱学与光谱分析,2020, 40(2):602 – 609.
GE Xiangyu, DING Jianli, WANG Jingzhe, et al. A new method for predicting soil moisture based on UAV hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2020, 40(2): 602 – 609. (in Chinese)

[54] 王浩,罗格平,王伟胜,等. 基于多源遥感数据的锡尔河中下游农田土壤含水率反演[J]. 自然资源学报,2019,34(12): 2717 – 2731.
WANG Hao, LUO Geping, WANG Weisheng, et al. Inversion of soil moisture content in the farmland in middle and lower reaches of Syr Darya River Basin based on multi-source remotely sensed data[J]. Journal of Natural Resources, 2019, 34(12): 2717 – 2731. (in Chinese)