

基于高光谱和机器学习模型的冬小麦土壤含水率监测研究

唐子竣<sup>1,2</sup> 张 威<sup>1,2</sup> 向友珍<sup>1,2</sup> 李志军<sup>1,2</sup> 张富仓<sup>1,2</sup> 陈俊英<sup>1,2</sup>

(1. 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;

2. 西北农林科技大学中国旱区节水农业研究院, 陕西杨凌 712100)

**摘要:** 为及时获取大田作物根区土壤含水率(Soil moisture content, SMC),实现精准灌溉,运用高光谱技术,通过连续2年(2019—2020年)田间试验采集了冬小麦拔节期不同土层深度 SMC 及高光谱数据,构建了3类植被指数(蓝、黄和红边面积等三边光谱参数,与冬小麦根区 SMC 相关性最高的任意两波段植被指数和前人研究与作物参数相关性较好的经验植被指数)并筛选与各土层深度 SMC 相关系数最高的植被指数,随后将筛选后的植被指数作为模型输入,分别采用随机森林(Random forest, RF)、反向神经网络(Back propagation neural network, BPNN)和极限学习机(Extreme learning machine, ELM)构建冬小麦拔节期不同土层深度 SMC 估算模型。结果表明,绝大部分三边参数、任意两波段植被指数和经验植被指数在深度0~20 cm 土层的 SMC 相关系数较20~40 cm 和40~60 cm 更高,在深度0~20 cm 土层两波段组合构建的光谱指数与 SMC 的相关系数最高,均超过0.8,其中 RI 与 SMC 的相关系数最高,为0.851,其波长组合为675 nm 和695 nm。RF 模型是 SMC 的最佳建模方法,其中深度0~20 cm 土层的模型精度最高,估算模型验证集的决定系数  $R^2$  达0.909,均方根误差(RMSE)为0.008,平均相对误差(MRE)为3.949%。本研究结果可为高光谱监测冬小麦根区 SMC 提供依据,为快速评估水分胁迫下的作物生长提供应用参考。

**关键词:** 冬小麦; 土壤含水率; 高光谱; 机器学习

中图分类号: S512.1; S127

文献标识码: A

文章编号: 1000-1298(2023)12-0350-09

OSID:



Monitoring of Soil Moisture Content of Winter Wheat Based on Hyperspectral and Machine Learning Models

TANG Zijun<sup>1,2</sup> ZHANG Wei<sup>1,2</sup> XIANG Youzhen<sup>1,2</sup> LI Zhijun<sup>1,2</sup> ZHANG Fucang<sup>1,2</sup> CHEN Junying<sup>1,2</sup>

(1. Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semiarid Areas,

Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Institute of Water-saving Agriculture in Arid Areas of China, Northwest A&F University, Yangling, Shaanxi 712100, China)

**Abstract:** Aiming to promptly obtain soil moisture content (SMC) in the root zone of field crops for precise irrigation, hyperspectral technology was utilized. Over a 2-year period spanning from 2019 to 2020, during the winter wheat jointing stage, SMC data at varying soil depths and hyperspectral data were collected. Three categories of vegetation indices were created, comprising ‘trilateral’ spectral parameters related to blue, yellow, and red-edge areas, any two-band vegetation indices with the highest correlation to winter wheat root zone SMC, and empirical vegetation indices showing good correlation with crop parameters from previous studies. The vegetation indices exhibited the highest correlation with SMC at different soil depths were selected. Subsequently, random forest (RF), back propagation neural network (BPNN), and extreme learning machine (ELM) were employed to construct SMC estimation models, using the selected vegetation indices as model inputs. The results revealed that a majority of the ‘trilateral’ spectral parameters spectral indices, any two-band vegetation indices, and empirical vegetation indices displayed stronger correlations with SMC in the 0~20 cm soil layer in comparison with the 20~40 cm and 40~60 cm layers. The two-band combinations in the 0~20 cm layer exhibited the highest correlations with SMC, all surpassing 0.8. Among which, RI showed the highest correlation with SMC at 0.851, utilizing a wavelength combination of 675 nm and 695 nm. The RF model emerged as the

收稿日期: 2023-05-31 修回日期: 2023-06-28

基金项目: 国家自然科学基金项目(52179045)

作者简介: 唐子竣(1998—),男,博士生,主要从事农业水利遥感与信息化研究,E-mail: Tangzijun@nwsuaf.edu.cn

通信作者: 向友珍(1973—),女,副教授,博士生导师,主要从事农业水利遥感与信息化研究,E-mail: youzhenxiang@nwsuaf.edu.cn

most effective modeling method for SMC, with the highest accuracy observed in the 0 ~ 20 cm soil layer. The coefficient of determination ( $R^2$ ) for the validation set of the estimation model in the 0 ~ 20 cm layer reached 0.909, and the root mean square error (RMSE) was 0.008, while the mean relative error (MRE) was 3.949%. The outcomes can serve as a foundation for hyperspectral monitoring of winter wheat root zone SMC and provide valuable insights for the rapid assessment of crop growth under water stress.

**Key words:** winter wheat; soil moisture content; hyperspectral; machine learning

0 引言

水是农业中必不可少的资源,土壤含水率(Soil moisture content, SMC)是作物生长的关键决定因素<sup>[1]</sup>,准确估算 SMC 可为有效灌溉提供可靠参考<sup>[2]</sup>。目前测量 SMC 的方法包括干燥前后土壤称量、使用土壤介电常数估算电导率、主动加热分布式温度传感器<sup>[3]</sup>、GPS 干涉反射测量法<sup>[4]</sup>和宇宙射线土壤湿度传感器<sup>[5]</sup>。然而,这些方法受到成本和测量频率的限制,不适用于区域 SMC 估算。

遥感反演技术可用于在高时空分辨率下估算植物生理状态和 SMC<sup>[6]</sup>。遥感数据可分为 3 种类型:光学数据、热红外数据和微波数据。光学遥感主要由可见光和近红外波段组成,其中包含地表反射率和太阳短波辐射的信息,对应于景观特征的光谱特性<sup>[7]</sup>。植物生理状态和 SMC 可以使用多种植被指数进行估算,包括预测植物水分状况<sup>[8]</sup>,以及仅从表层土壤光谱特征估算 SMC<sup>[9]</sup>。利用热红外传感器遥感监测不同含水率土壤的热力学特性和不同发育状态下作物的冠层温度,通过热惯性函数或计算作物水分胁迫来估算 SMC 或植物水分状态指数(CWSI)<sup>[10]</sup>,但这种方法的空间分辨率非常有限<sup>[11]</sup>。

由于微波可以检测土壤的介电特性,因此微波遥感越来越多地用于估算 SMC<sup>[12]</sup>。微波遥感产生的 SMC 数据产品应用广泛,包括土壤水分和海洋盐度(SMOS)<sup>[13]</sup>、微波扫描辐射计(AMSR-E)<sup>[14]</sup>和土壤水分主动被动(SMAP)<sup>[15]</sup>。然而,这些数据集对于植被茂密的地点是不连续的<sup>[16]</sup>。同时受分辨率的限制,卫星遥感不一定适用于区域农田等小型研究地点,并且由于固定的重访间隔和天气干扰,可能无法提供足够的数据<sup>[17]</sup>。

作为新兴的遥感平台,高光谱技术因其信息量大、无破坏、非接触、零污染、简便易行等特点,在 SMC 监测方面具有巨大潜力,为区域农田墒情的高效无损监测提供了一种技术手段。目前已有一些关于 SMC 反演的研究,已由全波段反射率的反演<sup>[18]</sup>逐渐转向基于植被指数的反演方法<sup>[19]</sup>。因为植被指数具有消除波段过拟合问题的优点,可以使统计

分析结果更具说服力<sup>[20]</sup>。目前已有一些关于构建植被指数反演 SMC 的研究<sup>[19,21]</sup>,证明基于植被冠层光谱的植被指数对于 SMC 的定量反演是可行的。

虽然通过构建固定波长的植被指数可以在一定程度上准确反演 SMC,但对于不同的研究对象,由于生长环境、生长期等因素的不同,作物本身的生理信息也会不同,从而导致光谱特性不同。在这种情况下,使用相同的波长可能会造成光谱数据的不充分利用,计算出来的植被指数反演模型有一定的局限性,模型的精度也会受到限制<sup>[22]</sup>。为解决上述问题,拟构建 3 类植被指数进行小麦根区 SMC 的估算:①蓝、黄和红边面积等三边光谱参数。②选取与小麦根区 SMC 相关性最高的最优植被指数,即在波长 350 ~ 1 830 nm 范围内的最佳组合指数。③前人研究与作物参数相关性较好的经验植被指数。拔节期是冬小麦生长的关键时期,标志着小花原基分化的开始。作为一个与生殖生长和无性生长密切相关的旺盛生长时期,提高分蘖率需要充足的水分、养分和光照条件,因此这一时期的 SMC 对小麦来说至关重要<sup>[23]</sup>。

因此,本文以关中地区拔节期冬小麦为研究对象,利用 ASD Field-Spec 3 型背挂式野外高光谱仪获取光谱数据并通过相关系数法筛选出与 SMC 均敏感的三边参数、任意两波段植被指数和经验植被指数,随后采用随机森林(Random forest, RF)、反向神经网络(Back propagation neural network, BPNN)和极限学习机(Extreme learning machine, ELM)对各深度土层 SMC 进行建模,并比较模型精度,得出反演 SMC 的最佳回归方法和最佳监测深度,以期研究准确、无损、快速的冬小麦 SMC 监测技术提供理论依据。

1 材料与方法

1.1 研究区概况及试验设计

试验于 2019 年和 2020 年在西北农林科技大学中国旱区节水农业研究院(34°14'N, 108°10'E)(图 1)进行,该地区属半干旱区,年平均降水量 632 mm,蒸发量 1 500 mm。试验区内共有 34 个试验小区,每块试验样地长 7 m,宽 3 m。种植的冬小

麦品种为小偃 22。试验设置了 4 个施氮量,分别为 100 (N1)、160 (N2)、220 (N3)、280 kg/hm<sup>2</sup> (N4)。同时设置了尿素 (U)、缓释肥 (SRF)、UNS1 (U、SRF 之比为 3/7) 和 UNS2 (U、SRF 之比为 1/4) 4 种施肥类型,以不使用氮肥作为对照处理 (CK),共 17 个处理,试验设置 2 个重复。施氮肥、磷肥 (P<sub>2</sub>O<sub>5</sub> 120 kg/hm<sup>2</sup>) 和钾肥 (K<sub>2</sub>O 100 kg/hm<sup>2</sup>) 作为基肥,播前施入 0~15 cm 土层。冬小麦 (小偃 22) 的播种量为 180 kg/hm<sup>2</sup>。冬小麦 2018 年 10 月 15 日和 2019 年 10 月 15 日播种,2019 年 6 月 25 日和 2020 年 6 月 25 日收获。




图 1 试验区地理位置

1.2 数据采集及预处理

1.2.1 光谱数据获取

冬小麦冠层光谱反射率采用 ASD Field-Spec 3 型背挂式野外高光谱仪 (Analytical Spectral Devices, Inc., St, Boulder, CO, 美国) 测定,仪器的详细介绍及采集方法参照文献[10]。分别于 2019 年 3 月 31 日和 2020 年 4 月 3 日 (拔节期) 测定,数据测量时天气晴朗无风,测定时间为 11:00—13:00。每个小区选取能代表该小区长势的 3 个样方进行测定,每个样方每次采集 9 条光谱曲线,以平均值作为该样方的光谱反射率<sup>[11]</sup>,共采集 68 组数据。

1.2.2 土壤含水率获取

光谱信息采集完成后,在每个试验小区利用土钻取土干燥法进行小麦根区 SMC 的测定,根据小麦主要根系活动层所在深度 (0~60 cm),按照 0~20 cm、20~40 cm 和 40~60 cm 分层取样,土样取出后迅速装入铝盒称量土壤质量,在 105℃ 下干燥后再称量并计算得到土壤质量含水率,根据土壤容重 (1.41 g/cm<sup>3</sup>) 最终计算得到土壤体积含水率。

1.2.3 光谱数据预处理

为了减少 (消除) 背景噪声、基线漂移及杂散光等无用信息对高光谱反射率曲线的影响,本文采用 Savitzky-Golay 卷积平滑对光谱数据进行预处

理<sup>[7]</sup>,采用二次多项式、平滑点数为 9 进行函数拟合和滤波去噪。

1.3 植被指数的选择及构建

植被指数可以反映作物长势和营养状态<sup>[9]</sup>。本研究通过构建 3 类植被指数进行小麦根区 SMC 的估算:①蓝、黄和红边面积等三边光谱参数。②选取与小麦根区 SMC 相关性最高的最优植被指数,即在波长 350~1 830 nm 范围内的最佳组合指数。③前人研究与作物参数相关性较好的经验植被指数。共选取 14 个植被指数:蓝边 (490~530 nm) 内最大一阶导数  $D_b$ <sup>[24]</sup>、黄边 (462~642 nm) 内最大一阶导数  $D_y$ <sup>[25]</sup>、红边 (670~760 nm) 内最大一阶导数  $D_r$ <sup>[26]</sup>、绿峰 (510~560 nm) 反射率最大值  $R_g$ <sup>[27]</sup>、红谷 (650~690 nm) 反射率最小值  $R_r$ <sup>[28]</sup>、蓝边 (490~530 nm) 面积  $S_b$ <sup>[29]</sup>、黄边 (462~642 nm) 面积  $S_y$ <sup>[29]</sup>、红边 (670~760 nm) 面积  $S_r$ <sup>[29]</sup>、差值植被指数  $DI$ <sup>[22]</sup>、比值植被指数  $RI$ <sup>[20]</sup>、归一化植被指数  $NDVI$ <sup>[23]</sup>、红边归一化植被指数  $RNDVI$ <sup>[30]</sup>、红边指数  $VOG$ <sup>[31]</sup> 和光化学反射指数  $PRI$ <sup>[32]</sup>。

1.4 模型建立方法

首先,分析植被指数与各深度土层 SMC 的相关性,分别筛选出与各深度土层 SMC 相关系数最高的 5 个植被指数作为模型的输入变量,随后分别利用随机森林、极限学习机和反向神经网络对各深度土层 SMC 进行建模<sup>[23,33]</sup>。在 RF 模型的构建中,经过参数优化和多次训练后,LAI 模型和 DM 模型中的决策树数均设置为 500<sup>[34]</sup>。ELM 模型使用 Sigmoid 函数构建,在  $[-1,1]$  范围内随机生成隐藏层参数 ( $a_i, b_i$ ) ( $i = 1, 2, \dots, L$ ),将隐藏层节点数设置为 1 000<sup>[33]</sup>;并将神经元数量以 15 为初值,15 为步长逐步增加到 120,每个模型运行 50 次选择最优训练结果,神经元数量最终确定为 60。BPNN 中隐藏层传递函数设置为 TANSIG,基于数值优化理论的 Levenbeger-Marquardt (Train-LM) 算法被用作网络训练函数,经过多次训练,确定中间层的神经元数量为 15 个<sup>[22]</sup>。

1.5 样本集划分与模型评价

试验于小麦拔节期共采集 68 份有效样本,剔除异常值之后随机选取 2/3 作为建模集,剩余 1/3 作为验证集。表 1 为建模集和验证集的样本数量及各深度土层 SMC 的统计特征。

为了验证模型预测精度和预测能力,本研究选取决定系数 (Determination coefficient,  $R^2$ )、均方根误差 (Root mean square error, RMSE) 和平均相对误差 (Mean relative error, MRE) 3 个评价指标用来评价

表 1 冬小麦各深度土层土壤含水率的描述性统计

Tab.1 Descriptive statistics of soil moisture content in different depths of winter wheat

| 指标     | 0 ~ 20 cm |       | 20 ~ 40 cm |       | 40 ~ 60 cm |       |
|--------|-----------|-------|------------|-------|------------|-------|
|        | 建模集       | 验证集   | 建模集        | 验证集   | 建模集        | 验证集   |
| 样本量    | 44        | 22    | 44         | 22    | 44         | 22    |
| 最大值    | 0.220     | 0.204 | 0.206      | 0.194 | 0.212      | 0.194 |
| 最小值    | 0.130     | 0.134 | 0.118      | 0.117 | 0.126      | 0.125 |
| 平均值    | 0.182     | 0.172 | 0.167      | 0.153 | 0.174      | 0.164 |
| 标准差    | 0.023     | 0.022 | 0.021      | 0.020 | 0.022      | 0.021 |
| 变差系数/% | 12.7      | 12.8  | 12.6       | 13.1  | 12.6       | 12.8  |

模型精度<sup>[35]</sup>。其中  $R^2$  越接近 1, RMSE 和 MRE 越接近 0, 说明模型拟合效果越好。

2 结果与分析

2.1 植被指数与不同深度土壤含水率的相关性分析

各植被指数与不同深度 SMC 的相关性分析结果如表 2 所示, 其中 RI、DI 和 NDVI 的波长组合筛选过程见图 2, 上述 3 种指数与不同深度 SMC 的相

表 2 植被指数与各深度土层土壤含水率相关系数计算结果

Tab.2 Calculation of correlation coefficients between vegetation index and SMC

| 指数                              | 深度/cm  |         |         |
|---------------------------------|--------|---------|---------|
|                                 | 0 ~ 20 | 20 ~ 40 | 40 ~ 60 |
| 蓝边 (490 ~ 530 nm) 内最大一阶导数 $D_b$ | 0.619  | 0.420   | 0.505   |
| 黄边 (462 ~ 642 nm) 内最大一阶导数 $D_y$ | 0.208  | 0.241   | 0.225   |
| 红边 (670 ~ 760 nm) 内最大一阶导数 $D_r$ | 0.651  | 0.498   | 0.410   |
| 绿峰 (510 ~ 560 nm) 反射率最大值 $R_g$  | 0.493  | 0.434   | 0.440   |
| 红谷 (650 ~ 690 nm) 反射率最小值 $R_r$  | 0.371  | 0.349   | 0.335   |
| 蓝边 (490 ~ 530 nm) 面积 $S_b$      | 0.767  | 0.592   | 0.662   |
| 黄边 (462 ~ 642 nm) 面积 $S_y$      | 0.170  | 0.203   | 0.166   |
| 红边 (670 ~ 760 nm) 面积 $S_r$      | 0.527  | 0.428   | 0.336   |
| 差值植被指数 DI                       | 0.841  | 0.708   | 0.703   |
| 比值植被指数 RI                       | 0.851  | 0.705   | 0.636   |
| 归一化植被指数 NDVI                    | 0.842  | 0.692   | 0.656   |
| 红边归一化植被指数 RNDVI                 | 0.556  | 0.465   | 0.433   |
| 红边指数 VOG                        | 0.769  | 0.596   | 0.561   |
| 光化学反射指数 PRI                     | 0.390  | 0.303   | 0.312   |

关系数及波长位置结果如图 2 和表 3 所示。结果表明: 绝大部分三边参数、任意两波段植被指数和经验




图 2 DI、RI 和 NDVI 与不同土层深度土壤含水率的相关系数  
Fig. 2 Correlation coefficient diagrams of DI, RI and NDVI with SMC in different soil depths

表 3 任意两波段植被指数与各土层土壤含水率  
相关系数最大值及波长位置

Tab.3 Maximum correlation coefficient and wavelength  
position of any two band vegetation index and soil  
moisture content in each soil layer

| 植被指数 | 0 ~ 20 cm  |                      | 20 ~ 40 cm |                      | 40 ~ 60 cm |                      |
|------|------------|----------------------|------------|----------------------|------------|----------------------|
|      | $r_{\max}$ | 波长位置<br>( $i,j$ )/nm | $r_{\max}$ | 波长位置<br>( $i,j$ )/nm | $r_{\max}$ | 波长位置<br>( $i,j$ )/nm |
| DI   | 0.841      | (756,759)            | 0.708      | (671,695)            | 0.703      | (674,695)            |
| RI   | 0.851      | (675,695)            | 0.705      | (756,757)            | 0.636      | (754,755)            |
| NDVI | 0.842      | (759,756)            | 0.692      | (756,757)            | 0.656      | (756,757)            |

植被指数在深度 0 ~ 20 cm 土层的 SMC 最大相关系数  $r_{\max}$  较 20 ~ 40 cm 和 40 ~ 60 cm 更高,在 0 ~ 20 cm 土层深度两波段组合构建的植被指数与 SMC 的相关系数最高,均超过 0.8,其中 RI 与 SMC 的相关系数最高,为 0.851,其波长组合为 675 nm 和 695 nm。研究同时发现在各土层中筛选的两波段组合构建的植被指数所在的波长位置均在红边波长(670 ~

760 nm)内。在深度 0 ~ 20 cm、20 ~ 40 cm 和 40 ~ 60 cm 土层中筛选的植被指数均为 RI、DI、NDVI、 $S_b$  和 VOG,上述植被指数与其对应土层的 SMC 的相关系数均高于 0.55,且均通过显著性检验( $P < 0.05$ )。

2.2 不同深度土壤含水率监测模型构建

将 2.1 节中筛选的与各土层 SMC 相关系数最高的 5 个植被指数作为模型的输入,分别采用 RF、ELM 和 BPNN 进行建模,模型结果如图 3 和表 4 所示,表 4 给出了不同输入变量和建模方法组合的冬小麦不同土层深度 SMC 模型建模集及验证集的预测结果。从图表中发现,在深度 0 ~ 20 cm 土层的 SMC 估算模型中建模集和验证集的  $R^2$  均高于 0.8,表明浅层 SMC 估算模型具有良好的拟合精度。同时可以进一步观察到模型相同的前提下,不同土层深度的估算模型预测结果不相同,其中 0 ~ 20 cm 土层 SMC 估算模型建模集和验证集的  $R^2$  均高于 20 ~ 40 cm 土层和 40 ~ 60 cm 土层,且 RMSE 和




图 3 基于随机森林、反向神经网络和极限学习机的冬小麦各土层土壤含水率的预测结果

Fig.3 Prediction results of soil moisture content in each soil layer of winter wheat based on random forest, back propagation neural network and extreme learning machine

表 4 SMC 估算模型精度检验结果对比  
Tab.4 Comparison of precision test results of  
estimation models of SMC

| 模型   | 土层深度/cm | 建模集 $R^2$ | 验证集 $R^2$ | 建模集 RMSE | 验证集 RMSE | 建模集 MRE/% | 验证集 MRE/% |
|------|---------|-----------|-----------|----------|----------|-----------|-----------|
| RF   | 0 ~ 20  | 0.942     | 0.909     | 0.006    | 0.008    | 2.516     | 3.949     |
|      | 20 ~ 40 | 0.746     | 0.573     | 0.011    | 0.015    | 5.563     | 8.448     |
|      | 40 ~ 60 | 0.538     | 0.589     | 0.016    | 0.014    | 5.045     | 7.021     |
| BPNN | 0 ~ 20  | 0.818     | 0.838     | 0.015    | 0.014    | 4.417     | 5.914     |
|      | 20 ~ 40 | 0.591     | 0.557     | 0.014    | 0.014    | 6.397     | 7.211     |
|      | 40 ~ 60 | 0.589     | 0.436     | 0.018    | 0.020    | 8.712     | 8.693     |
| ELM  | 0 ~ 20  | 0.814     | 0.801     | 0.017    | 0.019    | 4.388     | 8.605     |
|      | 20 ~ 40 | 0.716     | 0.651     | 0.016    | 0.015    | 4.893     | 9.385     |
|      | 40 ~ 60 | 0.653     | 0.501     | 0.023    | 0.019    | 6.339     | 10.075    |

MRE 均较低。在相同的土层深度下,RF 模型的建模集和验证集  $R^2$  高于其余模型,同时取得了较低的 RMSE 和 MRE。可以看出,RF 模型是 SMC 的最佳建模方法,其中深度 0 ~ 20 cm 土层的模型精度最高,估算模型验证集的决定系数  $R^2$  为 0.909,均方根误差为 0.008,平均相对误差为 3.949%。

3 讨论

光谱技术在快速有效监测土壤属性方面具有较大优势,其中高光谱以光谱信息丰富、波段连续性强而常用于监测 SMC<sup>[36]</sup>,但同时存在数据冗余、共线性强等特点导致反演模型适用性较差<sup>[37]</sup>。而植被指数能够充分利用高光谱丰富的信息,减少其他土壤信息对 SMC 的影响,去除冗余信息,降低模型的复杂性。

本文结果表明筛选过后的植被指数均与对应土层的 SMC 相关性达到显著水平,表明利用光谱信息可以用于监测不同深度土层的 SMC,这是因为 SMC 与植被冠层叶片的生长状态有一定的相关性,即 SMC 的高低会不同程度地影响叶片结构<sup>[38]</sup>。随着土层深度的增加,植被指数与 SMC 的相关性大致呈下降趋势,即浅层土水分状况能更好地被光谱信息反映,这是由于作物的根系分布主要集中在浅层土壤<sup>[39]</sup>,故浅层土壤的水分能够更好地被作物吸收从而影响冠层叶片。

研究发现在各土层中筛选的两波段组合构建的植被指数与其对应土层 SMC 的相关系数较三边参数和经验植被指数高,且其所在的波长位置均在红边范围内。这是因为对于不同的研究对象而言,由于生长环境、生长期等因素的不同,作物自身的生理信息会有所不同,从而产生不同的光谱特征,在该情况下使用相同的波长可能会导致光谱数据未得到充分利用<sup>[20]</sup>。同时有研究表明土壤水分的胁迫状况

可以体现在叶绿素含量上,水分的亏缺程度会影响作物叶绿素的合成<sup>[40]</sup>,因为红边对叶绿素含量具有很高的敏感性,叶绿素含量的变化和特征信息可以最大程度地反映在红边上,故作物根区土壤水分的状态可以反映在红边范围中<sup>[22]</sup>。

在本研究选取的 3 种建模方法中,基于 RF 的冬小麦 SMC 估算模型精度最好,表明 RF 在反演冬小麦 SMC 方面比其他模型更具优势。已有的研究表明估算模型的预测精度受到不同建模方法的显著影响<sup>[41]</sup>。本研究的结果表明,ELM 的预测精度低于 RF 模型,这些发现可以归因于 ELM 是基于前馈神经网络的模型,通常需要大量的数据进行训练从而获得较好的权重,但 RF 模型不太依赖数据量,因此当数据较少的时候 ELM 可能容易过拟合<sup>[42]</sup>;BPNN 的模型估计精度较低,这可能是由于样本相对较少导致泛化能力低所致<sup>[43]</sup>;另外 ELM 在面临大量数据时,会使噪声变量无法被有效的数据预处理步骤剔除,这导致其预测精度较低<sup>[44]</sup>;而 RF 是一种具有集成思维的机器学习方法,具有很强的自学习能力,对噪声和异常值的容忍度强,不易过拟合<sup>[45]</sup>。因此,RF 可作为冬小麦 SMC 监测和建模的首选方法。本研究在实际应用中可以更好地为作物土壤水分状态的监测提供实时、高效的技术服务。

目前,基于植被指数建立 SMC 的反演模型研究中仍有部分问题需要解决,本文使用的光谱信息较少,光谱预处理方法单一,有待于进一步尝试更多不同的光谱指标变换(如分数阶微分变换)在 SMC 反演模型中的应用,同时未来还应尝试利用多源遥感数据来充分挖掘土壤光谱信息,实现对 SMC 更为快速而准确的预测。

4 结论

(1)基于小区试验和实测高光谱数据,通过计算三边参数、任意两波段植被指数和经验植被指数并分别采用 RF、ELM 和 BPNN 模型对拔节期的冬小麦 SMC 进行了估算研究。

(2)各植被指数与浅层土壤(0 ~ 20 cm)SMC 的相关系数较深层土壤 SMC 高,任意两波段筛选的植被指数与 SMC 的相关性优于三边参数和典型植被指数,其中由波长 675 nm 和 695 nm 反射率构建的 RI 对 0 ~ 20 cm 的 SMC 最为敏感,相关系数为 0.851。

(3)当输入相同时,RF 模型是 SMC 的最佳建模方法,其中土层深度 0 ~ 20 cm 的模型精度最高,估算模型验证集的决定系数  $R^2$  高达 0.909,均方根误差为 0.008,平均相对误差为 3.949%。

## 参 考 文 献

- [1] 林人财,陈鹤,张德宁,等.基于作物水分胁迫指数的表层土壤含水率遥感估算[J].灌溉排水学报,2023,42(4):1-7.  
LIN Rencai, CHEN He, ZHANG Dening, et al. Estimating topsoil water content using crop water stress index and remote sensing technologies[J]. Journal of Irrigation and Drainage, 2023, 42(4):1-7. (in Chinese)
- [2] CHENG Minghan, JIAO Xiyun, GUO Weihua, et al. Temporal and spatial distribution characteristics of irrigation water requirement for main crops in the plain area of Hebei Province(dagger)[J]. Irrigation and Drainage, 2020, 69(5):1051-1062.
- [3] ROSA A, THOM A B, ROBERTO G, et al. Non-invasive water content estimation in a tuff wall by DTS[J]. Construction and Building Materials, 2019, 197:821-829.
- [4] KRISTINE M L. GPS interferometric reflectometry: applications to surface soil moisture, snow depth, and vegetation water content in the western United States[J]. Wiley Interdisciplinary Reviews: Water, 2016, 3(6):775-787.
- [5] EVANS J G, WARD H C, BLAKE J R, et al. Soil water content in southern England derived from a cosmic-ray soil moisture observing system—COSMOS-UK[J]. Hydrological Processes, 2016, 30(26):4987-4999.
- [6] VIRNODKAR S S, PACHGHARE V K, PATIL V C, et al. Remote sensing and machine learning for crop water stress determination in various crops: a critical review[J]. Precision Agriculture, 2020, 21:1121-1155.
- [7] JOÃO S, SHAKIB S, JOSÉ M S. Evaluation of normalized difference water index as a tool for monitoring pasture seasonal and Inter-Annual variability in a mediterranean Agro-Silvo-Pastoral system[J]. Water, 2019, 11(1):62.
- [8] ZHOU Jing, ZHOU Jianfeng, YE Heng, et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery[J]. Computers and Electronics in Agriculture, 2020, 175:105576.
- [9] SHARMA M, BANGOTRA P, GAUTAM A S, et al. Sensitivity of normalized difference vegetation index (NDVI) to land surface temperature, soil moisture and precipitation over district Gautam Buddh Nagar, UP, India[J]. Stochastic Environmental Research and Risk Assessment: Research Journal, 2021, 36:1779-1789.
- [10] 张智韬,边江,韩文霆,等.无人机热红外图像计算冠层温度特征数诊断棉花水分胁迫[J].农业工程学报,2018,34(15):77-84.  
ZHANG Zhitao, BIAN Jiang, HAN Wenting, et al. Cotton moisture stress diagnosis based on canopy temperature characteristics calculated from UAV thermal infrared image[J]. Transactions of the CSAE, 2018, 34(15):77-84. (in Chinese)
- [11] MAMMATT S, WOLFGANG R, PEYMAN Z R. Soil moisture derived using two apparent thermal inertia functions over Canterbury, New Zealand[J]. Journal of Applied Remote Sensing, 2014, 8(1):089999.
- [12] DONG Jianzhi, WADE T C, KENNETH J T, et al. Comparison of microwave remote sensing and land surface modeling for surface soil moisture climatology estimation[J]. Remote Sensing of Environment, 2020, 242:111756.
- [13] KERR Y H, PHILIPPE W, WIGNERON J P. The SMOS mission: new tool for monitoring key elements of the global water cycle[J]. Proceedings of the IEEE, 2010, 98(5):666-687.
- [14] KARTHIKEYAN L, PAN Ming, ALEXANDRA G K, et al. Simultaneous retrieval of global scale vegetation optical depth, surface roughness, and soil moisture using X-band AMSR-E observations[J]. Remote Sensing of Environment, 2019, 234:111473.
- [15] YE Nan, JEFFREY P W, WU Xiaoling, et al. The soil moisture active passive experiments: validation of the SMAP products in Australia[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020,99:1-18.
- [16] SONIA I S, THIERRY C, EDOUARD L D, et al. Investigating soil moisture-climate interactions in a changing climate: a review[J]. Earth Science Reviews, 2010, 99(3-4):125-161.
- [17] 于铁龙,杨兰,张婷婷,等.水稻全生育期近地空农情遥感精准监测应用[J].中国农业文摘-农业工程,2022,34(6):55-64.  
YU Tielong, YANG Lan, ZHANG Tingting, et al. Application of remote sensing to accurate monitoring of near-ground and air agricultural conditions during the whole growth period of rice[J]. Agricultural Science and Engineering in China, 2022, 34(6):55-64. (in Chinese)
- [18] 陈俊英,邢正,张智韬,等.基于高光谱定量反演模型的污水综合水质评价[J].农业机械学报,2019,50(11):200-209.  
CHEN Junying, XING Zheng, ZHANG Zhitao, et al. Comprehensive evaluation of waste water quality based on quantitative inversion model hyperspectral technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11):200-209. (in Chinese)
- [19] 王敬哲,丁建丽,马轩凯,等.基于光谱指数的绿洲农田土壤含水率无人机高光谱检测[J].农业机械学报,2018,49(11):164-172.  
WANG Jingzhe, DING Jianli, MA Xuankai, et al. Detection of soil moisture content based on UAV-derived hyperspectral imagery and spectral index in oasis cropland[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11):164-172. (in Chinese)
- [20] 刘爽,于海业,张郡赫,等.基于最优光谱指数的大豆叶片叶绿素含量反演模型研究[J].光谱学与光谱分析,2021,

41(6):1912–1919.

LIU Shuang, YU Haiye, ZHANG Junhe, et al. Study on inversion model of chlorophyll content in soybean leaf based on optimal spectral indices[J]. Spectroscopy and Spectral Analysis, 2021, 41(6):1912–1919. (in Chinese)

[21] 张军,邓俊涛,倪国威,等. 基于植被指数的猕猴桃根区土壤水分反演影响因素研究[J]. 农业机械学报, 2022, 53(12): 223–230.

ZHANG Jun, DENG Juntao, NI Guowei, et al. Influencing factors of soil moisture content inversion in kiwifruit root region based on vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12):223–230. (in Chinese)

[22] SHI Hongzhao, GUO Jinjin, AN Jiaqi, et al. Estimation of chlorophyll content in soybean crop at different growth stages based on optimal spectral index[J]. Agronomy, 2023, 13(3):663.

[23] TANG Zijun, GUO Jinjin, XIANG Youzhen, et al. Estimation of leaf area index and above-ground biomass of winter wheat based on optimal spectral index[J]. Agronomy, 2022, 12(7):1729.

[24] 吕小东,王建光,孙启忠,等. 苜蓿人工草地高光谱遥感估产模型的研究[J]. 草业学报, 2014, 23(1): 84–91.

LÜ Xiaodong, WANG Jianguang, SUN Qizhong, et al. Research on the hyperspectral remote sensing estimation models for the fresh yield of alfalfa grassland[J]. Journal of Grass Industry, 2014, 23(1):84–91. (in Chinese)

[25] 俞欣妍,刘健,余坤勇,等. 叶片—冠层尺度的毛竹林分光谱特征[J]. 西北林学院学报, 2017, 32(3):7–13.

YU Xingyan, LIU Jian, YU Kunyong, et al. Spectral scale differences between leaf and canopy of spectral characteristics of phyllostachys pubescens forest[J]. Journal of Northwest Forestry University, 2017, 32(3):7–13. (in Chinese)

[26] 李明泽,赵小红,刘钺,等. 基于机载高光谱影像的植被冠层叶绿素反演[J]. 应用生态学报, 2013, 24(1):177–182.

LI Mingze, ZHAO Xiaohong, LIU Yue, et al. Inversion of vegetation canopy's chlorophyll content based on airborne hyperspectral image[J]. Journal of Applied Ecology, 2013, 24(1):177–182. (in Chinese)

[27] 卓伟,于旭峰,李欣庭,等. 高光谱成像技术实现马铃薯叶片叶绿素无损检测[J]. 光学仪器, 2020, 42(6):1–8.

ZHUO Wei, YU Xufeng, LI Xinting, et al. Non-destructive detection of potato leaf chlorophyll with hyperspectral imaging technology[J]. Optical Instrument, 2020, 42(6):1–8. (in Chinese)

[28] 康丽,高睿,孔庆明,等. 水稻叶片 SPAD 值高光谱成像估测[J]. 东北农业大学学报, 2020, 51(10):89–96.

KANG Li, GAO Rui, KONG Qingming, et al. Estimation of SPAD value of rice leaves based on hyperspectral image[J]. Journal of Northeast Agricultural University, 2020, 51(10):89–96. (in Chinese)

[29] 王冰,何金有,张鹏杰,等. 基于高光谱的内蒙古大兴安岭白桦叶片叶绿素含量估算[J]. 西部林业科学, 2022, 51(4): 11–18.

WANG Bing, HE Jinyou, ZHANG Pengjie, et al. Leaf chlorophyll content estimation of *Betula platyphylla* in Daxing'anling based on hyperspectral[J]. Journal of West China Forestry Science, 2022, 51(4):11–18. (in Chinese)

[30] 王克晓,周蕊,李波,等. 基于高光谱的油菜叶片 SPAD 值估测模型比较[J]. 福建农业学报, 2021, 36(11):1272–1279.

WANG Kexiao, ZHOU Rui, LI Bo, et al. Comparison of estimation models for hyperspectral-based rape leaf SPAD[J]. Fujian Journal of Agricultural Sciences, 2021, 36(11):1272–1279. (in Chinese)

[31] 王玉娜,李粉玲,王伟东,等. 基于无人机高光谱的冬小麦氮素营养监测[J]. 农业工程学报, 2020, 36(22):31–39.

WANG Yu'na, LI Fenling, WANG Weidong, et al. Monitoring of winter wheat nitrogen nutrition based on UAV hyperspectral images[J]. Transactions of the CSAE, 2020, 36(22):31–39. (in Chinese)

[32] 刘杨,孙乾,冯海宽,等. 基于小波分析的马铃薯地上生物量估算[J]. 光谱学与光谱分析, 2021, 41(4):1205–1212.

LIU Yang, SUN Qian, FENG Haikuan, et al. Estimation of above-ground biomass of potato based on wavelet analysis[J]. Spectroscopy and Spectral Analysis, 2021, 41(4):1205–1212. (in Chinese)

[33] 唐子竣,向友珍,王辛,等. 基于不同分析模型的大豆叶片 SPAD 值和 LAI 光谱估算比较[J]. 大豆科学, 2023, 42(1): 55–63.

TANG Zijun, XIANG Youzhen, WANG Xin, et al. Comparison of SPAD value and LAI spectral estimation of soybean leaves based on different analysis models[J]. Soybean Science, 2023, 42(1):55–63. (in Chinese)

[34] 陆军胜,陈绍民,黄文敏,等. 采用 SEPLS–ELM 模型估算夏玉米地上部生物量和叶面积指数[J]. 农业工程学报, 2021, 37(18): 128–135.

LU Junsheng, CHEN Shaomin, HUANG Wenmin, et al. Estimation of aboveground biomass and leaf area index of summer maize using SEPLS–ELM model[J]. Transactions of the CSAE, 2021, 37(18):128–135. (in Chinese)

[35] 陈俊英,王新涛,张智韬,等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. 农业机械学报, 2019, 50(12): 161–169.

CHEN Junying, WANG Xintao, ZHANG Zhitao, et al. Soil salinization monitoring method based on UAV–satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12):161–169. (in Chinese)

[36] ZHANG Zipeng, DING Jianli, WANG Jiangzhe, et al. Prediction of soil organic matter in northwestern China using fractional-order derivative spectroscopy and modified normalized difference indices[J]. Catena, 2019, 185:104257.

[37] 张俊华,尚天浩,陈睿华,等. 基于光谱 FOD 与优化指数的银川平原土壤有机质含量反演[J]. 农业机械学报, 2022,

53(11):379–387.

ZHANG Junhua, SHANG Tianhao, CHEN Ruihua, et al. Inversion of soil organic matter content in Yinchuan plain using field spectral fractional-order derivatives combined with spectral optimization index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11):379–387. (in Chinese)

[38] 范梅凤,蔡焕杰,李志军. 基于高光谱遥感水分指数的叶片与土壤含水率监测研究[J]. 灌溉排水学报, 2014, 33(增刊1):213–217.

FAN Meifeng, CAI Huanjie, LI Zhijun, et al. Monitoring leaf and soil moisture status based on hyperspectral-derived vegetation moisture indices[J]. Journal of Irrigation and Drainage, 2014, 33(Supp.1):213–217. (in Chinese)

[39] 何华,康绍忠,曹红霞. 灌溉施肥部位对玉米同化物分配和水分利用的影响[J]. 西北植物学报, 2003(8):1458–1461.

HE Hua, KANG Shaozhong, CAO Hongxia. Effect of fertigation depth on dry matter partition and water use efficiency of corn[J]. Acta Botanica Boreali-occidentalia Sinica, 2003(8):1458–1461. (in Chinese)

[40] GUO Jinjin, FAN Junliang, XIANG Youzhen, et al. Maize leaf functional responses to blending urea and slow-release nitrogen fertilizer under various drip irrigation regimes[J]. Agricultural Water Management, 2022, 262:107396.

[41] 夏天,吴文斌,周清波,等. 冬小麦叶面积指数高光谱遥感反演方法对比[J]. 农业工程学报, 2013, 29(3):139–147.

XIA Tian, WU Wenbin, ZHOU Qingbo, et al. Comparison of two inversion methods for winter wheat leaf area index based on hyperspectral remote sensing[J]. Transactions of the CSAE, 2013, 29(3):139–147. (in Chinese)

[42] HUANG Guangbin, ZHU Qinyu, SIEW C. Extreme learning machine: a new learning scheme of feedforward neural networks[J]. Neurocomputing, 2006, 70:489–501.

[43] 张银,周孟然. 人工神经网络 BP 算法在近红外光谱分析中的应用[J]. 红外, 2006(11):1–4.

ZHANG Yin, ZHOU Mengran. Application of artificial neural network BP algorithm in near infrared spectroscopy[J]. Infrared, 2006(11):1–4. (in Chinese)

[44] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2011, 42(2):513–529.

[45] FU Zhaopeng, JIANG Jie, GAO Yang, et al. Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle[J]. Remote Sensing, 2020, 12(3):508.

~~~~~

(上接第 241 页)

[22] 束美艳,李世林,魏家玺,等. 基于无人机平台的柑橘树冠信息提取[J]. 农业工程学报,2021,37(1):68–76.

SHU Meiyang, LI Shilin, WEI Jiayi, et al. Extraction of citrus crown parameters using UAV platform[J]. Transactions of the CSAE, 2021, 37(1):68–76. (in Chinese)

[23] BESL P J, MCKAY N D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2):239–256.

[24] ZHANG W M, QI J B, WAN P, et al. An easy-to-use airborne LiDAR data filtering method based on cloth simulation[J]. Remote Sensing, 2016, 8(6):501.

[25] SHAO J, ZHANG W M, SHEN A J, et al. Seed point set-based building roof extraction from airborne LiDAR point clouds using a top-down strategy[J]. Automation in Construction, 2021, 126:103660.

[26] 郝红科. 基于机载激光雷达的森林参数反演研究[D]. 杨凌:西北农林科技大学,2019.

HAO Hongke. Inversion of forest parameters using airborne LiDAR[D]. Yangling: Northwest A&F University, 2019. (in Chinese)

[27] 许子乾. 基于无人机航测与激光雷达技术的林分特征及生物量估测[D]. 南京:南京林业大学,2019.

XU Ziqian. Estimation on stand characteristic parameters and biomass of forest by UAV aerial photogrammetry and LiDAR[D]. Nanjing: Nanjing Forestry University, 2019. (in Chinese)

[28] MIKITA T, KLIMANEK M, CIBULKA M. Evaluation of airborne laser scanning data for tree parameters and terrain modelling in forest environment[J]. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, 2013, 61(5):1339–1347.

[29] HODGSON M E, JENSEN J R, RABER G, et al. An evaluation of Lidar-derived elevation and terrain slope in leaf-off conditions[J]. Photogrammetric Engineering & Remote Sensing, 2005, 71:817–823.

[30] 李明龙. 不同栽培条件对油菜三维结构的影响研究[D]. 武汉:华中农业大学,2022.

LI Minglong. Effects of different cultivation conditions on three-dimensional structure of rapeseed[D]. Wuhan: Huazhong Agricultural University, 2022. (in Chinese)

[31] 王庆,车荧璞,柴宏红,等. 基于无人机可见光与激光雷达的甜菜株高定量评估[J]. 农业机械学报,2021,52(3):178–184.

WANG Qing, CHE Yingpu, CHAI Honghong, et al. Quantitative evaluation of sugar beet plant height based on UAV–RGB and UAV–LiDAR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3):178–184. (in Chinese)