

文章编号:1671-6833(2024)05-0111-08

基于无人机多光谱与热红外数据的冬小麦土壤水分反演

张成才¹, 侯佳彤¹, 王蕊¹, 姜明梁^{1,2}, 祝星星¹

(1. 郑州大学 水利与交通学院, 河南 郑州 450001; 2. 中国农业科学院农田灌溉研究所, 河南 新乡 453002)

摘要: 引入植被覆盖度会在一定程度上提高土壤水分反演模型的精度, 但大多数研究均基于归一化植被指数 $NDVI$ 估算植被覆盖度, 未深入研究基于其他植被指数估算植被覆盖度对模型的影响。为此, 以河南省驻马店市西平县人和乡冬小麦部分种植区域为实验区, 基于分辨率高、机动性强的无人机平台搭载多光谱与热红外成像仪开展冬小麦覆盖地表的土壤水分反演研究, 探究引入不同植被覆盖度参数后模型精度的变化, 并弥补基于卫星遥感影像的土壤水分监测分辨率低、时效性差的不足。基于随机森林算法, 将温度植被干旱指数 $TVDI$ 、垂直干旱指数 PDI 两种干旱指数分别与 7 种植被指数估算的植被覆盖度参数耦合搭建土壤水分反演模型, 并根据最优模型的反演结果对实验区的土壤水分空间分布情况进行分析。同时, 建立耦合 $TVDI$ 与 PDI 指数、不引入植被覆盖度的土壤水分反演模型 TP 模型为对照组。结果表明: 在 0~10 cm 和 >10~20 cm 深度时, TP 模型的决定系数 R^2 分别为 0.606、0.670, 均方根误差 $RMSE$ 分别为 0.045、0.041。7 种引入植被覆盖度的模型精度较 TP 模型精度均有一定程度的提升, 其中最优化模型 TP_{OSAVI} 的 R^2 较 TP 模型分别提高 0.143、0.158, $RMSE$ 分别降低 0.7 百分点、0.8 百分点。基于干旱指数引入植被覆盖度能够提高模型精度, 且不同植被覆盖度参数对模型精度的提升程度有差异。

关键词: 土壤水分反演; 无人机遥感; 多光谱; 热红外; 随机森林; 干旱指数; 植被覆盖度

中图分类号: TP79; S152.7

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2024.05.002

土壤水分是农田旱涝的指示因子, 只有土壤水分适宜, 作物才能保持良好的生长态势, 从而实现作物产量及经济效益的最大化。因此, 土壤水分监测对保障农作物的生长发育、促进精准灌溉技术的实施以及推进农业经济发展均有积极的作用^[1]。传统土壤水分测定方法如烘干法、电阻法等具有较高的精度, 但需要消耗大量的人力、物力而且监测的时效性不高、在空间上缺乏连续性。遥感监测方法获取区域地表土壤水分的速度快, 在空间上具有连续性^[2]。根据遥感平台的不同可将遥感技术分为卫星遥感和无人机遥感。卫星遥感的观测面积大, 但精度低、易受外部条件影响。相比于卫星遥感, 无人机遥感具有分辨率高、机动性强、时效性高等优点^[3], 且可以搭载多光谱、高光谱、热红外等多种传感器。基于无人机遥感进行土壤水分反演能够为卫星土壤水分产品的真实性检验奠定基础, 并可以通

过升尺度等方法补充卫星遥感所缺少的高精度数据, 实现大尺度、高精度的土壤水分监测^[4], 具有极大的应用价值。

干旱指数与土壤水分有一定的相关性, 诸多学者由此展开了基于干旱指数进行土壤水分监测的研究。葛少青等^[5]通过 $TVDI$ 、归一化植被指数 $NPDI$ 、 PDI 3 种干旱指数反演了沼泽湿地不同深度下的土壤水分。蔡亮红等^[6]在 $TVDI$ 的基础上引入数字高程数据对地表温度进行校正, 提高了模型精度。张文江等^[7]基于归一化差异水分指数 $NDWI$ 构造了归一化水分距平指数 $NDWDI$ 检验四川盆地东部的旱情遥感观测响应, 结果表明: $NDWDI$ 能准确反映旱情的演变历程, 且不同植被覆盖类型对于干旱的敏感性存在差异。尽管干旱指数法有很多优点, 如运算简便、精度高、对气象数据的依赖度低等, 但其监测结果易受植被覆盖度影响, 具有一定的局限性^[8]。

收稿日期: 2024-02-16; 修订日期: 2024-04-18

基金项目: 国家自然科学基金资助项目(42241759); 河南省自然科学基金资助项目(222300420539); 河南省科技攻关项目(222102110176)

作者简介: 张成才(1964—), 男, 河南周口人, 郑州大学教授, 博士, 从事水利信息技术研究, E-mail: zhangcc2000@163.com。

引用本文: 张成才, 侯佳彤, 王蕊, 等. 基于无人机多光谱与热红外数据的冬小麦土壤水分反演[J]. 郑州大学学报(工学版), 2024, 45(5): 111-118. (ZHANG C C, HOU J T, WANG R, et al. Soil moisture inversion for winter wheat field based on UAV multispectral and thermal infrared data[J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(5): 111-118.)

植被覆盖会影响土壤蒸散发、改变土壤渗透性进而影响土壤含水量。杨志辉等^[9]发现土壤水分空间分布受多因子影响,其中植被覆盖度的影响最大,并基于植被覆盖度与表面反照率特征空间计算裸土反照率,提高了遥感土壤水分估算精度。Ghulam 等^[10]为减小植被对模型精度的影响,在 *PDI* 的基础上引入植被覆盖度,提出了改进垂直干旱指数,在植被覆盖度较高的地区具有更高的精度。朱燕香等^[11]将光合植被覆盖度引入 *OPTRAM* 模型,基于短波红外变换反射率与光合植被覆盖度特征空间构建土壤水分反演模型,提高了干湿边拟合效果及模型的精度。综上所述,在土壤水分反演模型中引入植被覆盖度能在一定程度上提高模型精度。因此,本研究利用无人机热红外及多光谱数据,选取 *TVDI* 与 *PDI* 两种干旱指数,引入 7 种植被指数估算的植被覆盖度,基于随机森林算法(RF)分别构建土壤水分反演模型。同时,建立综合 *TVDI* 与 *PDI* 指数的土壤水分反演模型 TP 模型为对照组。以期提高土壤水分监测精度,探究引入不同植被覆盖度参数后模型精度的变化,并为基于卫星遥感的大尺度农田土壤水分监测提供一定的参考。

1 材料与方法

1.1 实验区概况

本文选取河南省驻马店市西平县人和乡的冬小麦部分种植区为实验区(中心经纬度:33°29′1.75″N,114°2′40.72″E),位置示意图如图 1 所示。实验区总面积为 1.2 km²,该区域地处淮河流域,四季分明,农业资源较为丰富,实验区主要种植制度为一年两熟制,种植作物以冬小麦、夏玉米为主。本研究于 2023 年 3 月 14 日进行数据采集,实验区内的作物为拔节期的冬小麦。

1.2 数据来源及处理

1.2.1 无人机数据来源及处理

本研究中的无人机多光谱数据由 A4 机搭载 RedEdge-MX 传感器和 RedEdge-MX Blue 传感器获取,采集的多光谱影像共有 10 个光谱通道:B1 海岸蓝(波长 444 nm,带宽 28 nm)、B2 蓝(波长 475 nm,带宽 32 nm)、B3 绿(波长 531 nm,带宽 14 nm)、B4 绿(波长 560 nm,带宽 27 nm)、B5 红(波长 650 nm,带宽 16 nm)、B6 红(波长 668 nm,带宽 14 nm)、B7 红边(波长 705 nm,带宽 10 nm)、B8 红边(波长 717 nm,带宽 12 nm)、B9 红边(波长 740 nm,带宽 18 nm)、B10 近红(波长 842 nm,带宽 57 nm),影像分辨率为 0.05 m;热红外数据由 A4 机搭载 WIRIS




图 1 河南省驻马店市西平县人和乡冬小麦部分种植区示意图

Figure 1 Geographical location of some winter wheat planting areas in Renhe Township, Xiping County, Zhumadian City, Henan Province

PRO 成像仪获得,影像分辨率为 0.21 m。无人机飞行高度为 70 m,航带间隔为 17 m,飞行速度为 6 m/s。

无人机多光谱摄像机采集的原始数据为若干张 TIFF 格式的实验区局部遥感影像。在全自动无人机影像处理软件 Pix4Dmapper 中导入辐射标定板拍摄图像、实验区局部影像,并选择 Ag Multispectral 模板,设置输出坐标系,即可自动进行辐射校正,生成 10 张完整的实验区反射率影像,分别对应无人机多光谱摄像机的 10 个波段。无人机热红外原始数据也为局部的 TIFF 格式图像,经 Pix4Dmapper 软件处理可以得到实验区完整的热红外影像,并由式(1)进行换算,得到相应的地表温度:

T_s = 0.025DN_i + 173. (1)

式中:DN_i 为热红外数据的 DN 值。

1.2.2 实测数据采集及处理

土壤水分数据与无人机数据同步采集,采集深度为 0~10 cm 和 >10~20 cm(深度区间为左闭右开)。土壤含水量通过烘干法测定,并将获得的土壤质量含水量转换为土壤体积含水量,其表达式为

θ = ω × ρ_b. (2)

式中:ω 为土壤质量含水量;ρ_b 为土壤容重,单位为 g/cm³。

1.3 研究方法

1.3.1 温度植被干旱指数 TVDI

温度植被干旱指数基于归一化植被指数 *NDVI* 与地表温度的特征空间进行计算^[12]。然而,在植被覆盖度高的地区,*NDVI* 极易出现饱和的现象。这是因为 *NDVI* 是根据植被对红光和近红光的反射率不同建立的公式,但对二者比值进行了非线性变换,导致高值部分被抑制。相比之下,增强型植被指数

EVI 的计算并未涉及该比值,不存在容易饱和的缺陷^[13],且杨曦等^[14]经实验证实相较于基于 *NDVI* 构建的 *TVDI_N*,基于 *EVI* 构建的 *TVDI_E* 与土壤含水量(质量分数)的拟合结果更好。因此,本研究基于 *EVI-T_s* 特征空间构建 *TVDI*,其表达式如下:

$$TVDI_E = \frac{T_s - T_{min}}{T_{max} - T_{min}};$$

(3)

$$T_{min} = a + b \times EVI;$$

(4)

$$T_{max} = c + d \times EVI;$$

(5)

$$EVI = \frac{2.5(R_{nir} - R_{red})}{R_{nir} + 6R_{red} - 7.5R_{blue} + 1}。$$

(6)

式中:*T_{min}* 为特征空间湿边;*a*、*b* 为湿边系数;*T_{max}* 为特征空间干边;*c*、*d* 为干边系数;*R_{nir}*、*R_{red}*、*R_{blue}* 分别为近红光、红光、蓝光波段的反射率,本文中,*R_{nir}*、*R_{red}*、*R_{blue}* 分别对应 B10、B5、B2 波段。

1.3.2 垂直干旱指数 *PDI*

在 *R_{nir}-R_{red}* 光谱特征空间中,近红外波段反射率与红光波段反射率呈现出一条由近于原点发射的

“土壤基线”,特征空间内任意一点到土壤基线的垂线的距离即为垂直干旱指数 *PDI*^[15]。其表达式为

$$PDI = \frac{R_{red} + M \times R_{nir}}{\sqrt{M^2 + 1}};$$

(7)

$$R_{nir} = M \times R_{red} + I。$$

(8)

式中:*M* 和 *I* 分别为土壤基线的斜率和截距。

1.3.3 植被覆盖度 *f_v*

植被覆盖度是表征植被茂密程度、生长态势的指标。植被指数能够反映植被的生长状况,因此,可以利用植被指数估算植被覆盖度,公式如下^[16]:

$$f_{v_i} = \frac{VI - VI_{min}}{VI_{max} - VI_{min}}。$$

(9)

式中:*VI* 为植被指数;*VI_{max}* 和 *VI_{min}* 一般取一定置信度范围内的最大值与最小值,置信度的取值主要根据图像实际情况来定。

为探究不同植被覆盖度参数对模型精度的影响,选择不同植被指数估算植被覆盖度,并建立相应模型,计算式^[17]见表 1。

表 1 植被指数计算公式
Table 1 Vegetation index formula

植被指数	计算公式
土壤调整植被指数 SAVI	$(1 + L)(R_{nir} - R_{red}) / (R_{nir} + R_{red} + L)$
比值植被指数 RVI	R_{nir} / R_{red}
优化土壤调整植被指数 OSAVI	$1.16(R_{nir} - R_{red}) / (R_{nir} + R_{red} + 0.16)$
修正简单比值植被指数 mSRI	$(R_{red\ edge} - R_{blue}) / (R_{red\ edge} + R_{blue})$
修正土壤调整植被指数 MSAVI	$(2R_{nir} + 1 - \sqrt{(2R_{nir} + 1)^2 - 8(R_{nir} - R_{red})}) / 2$
归一化植被指数 NDVI	$(R_{nir} - R_{red}) / (R_{nir} + R_{red})$

注:*L* 为土壤调节系数,一般设为 0.5;*R_{red edge}* 为红边波段的反射率,选取 B9 波段。

1.3.4 随机森林回归

随机森林(RF)是一种从训练集中有放回地进行多次随机抽样的机器学习算法,如图 2 所示。

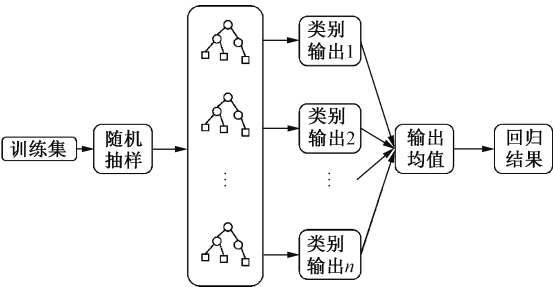


图 2 RF 算法示意图
Figure 2 RF algorithm diagram

RF 算法的基本结构为若干个相互独立的决策树^[18],每个决策树都有不同的训练结果,以所有决策树的均值作为最终的回归结果。RF 基于随机抽样和随机特征选择构建决策树,增加了决策树的多样性,能够大幅降低过拟合风险,更好地模拟多维变量之间的非线性关系^[19]。

1.3.5 评价指标

采用决定系数 *R²*、均方根误差 *RMSE*、平均绝对误差 *MAE* 和均方误差 *MSE* 验证模型精度。评价指标的计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (A_i - \hat{A}_i)^2}{\sum_{i=1}^n (A_i - \bar{A}_i)^2};$$

(10)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - \hat{A}_i)^2}{n}};$$

(11)

$$MAE = \frac{\sum_{i=1}^n |A_i - \hat{A}_i|}{n};$$

(12)

$$MSE = \frac{\sum_{i=1}^n (A_i - \hat{A}_i)^2}{n}。$$

(13)

式中:*A_i* 为第 *i* 个预测值;*A_i* 为第 *i* 个实测值;*A_i* 为

预测值的平均值。

2 结果与分析

2.1 干旱指数构建

2.1.1 温度植被干旱指数 TVDI

提取相同 EVI 下的最高温度和最低温度,建立实验区 EVI 与地物表面温度的特征空间。如图 3 所示,二者呈明显的梯形关系,随着 EVI 逐渐增大,最高温度呈显著的下降趋势,特征干边斜率较大;而最低温度基本保持不变,特征湿边斜率较小,且干边拟合效果优于湿边。




图 3 $EVI-T_s$ 特征空间图

Figure 3 $EVI-T_s$ feature space diagram

2.1.2 垂直干旱指数 PDI

$R_{nir}-R_{red}$ 光谱特征空间中土壤基线的提取结果如图 4 所示,根据式(8)即可计算实验区的 PDI 。




图 4 $R_{nir}-R_{red}$ 特征空间图

Figure 4 $R_{nir}-R_{red}$ feature space diagram

2.2 描述性统计

模型建模集与验证集的比例为 7:3。土壤体积分含水量的描述性统计结果见图 5。0~10 cm 深度时,全集、建模集、验证集的均值分别为 0.451、0.452 和 0.447,标准差分别为 0.071、0.073 和 0.066。>10~20 cm 深度时,全集、建模集、验证集的均值分别为 0.459、0.457 和 0.461,标准差分别为 0.063、0.064 和 0.063。总体上看,全集与建模集的统计结果较为相近。

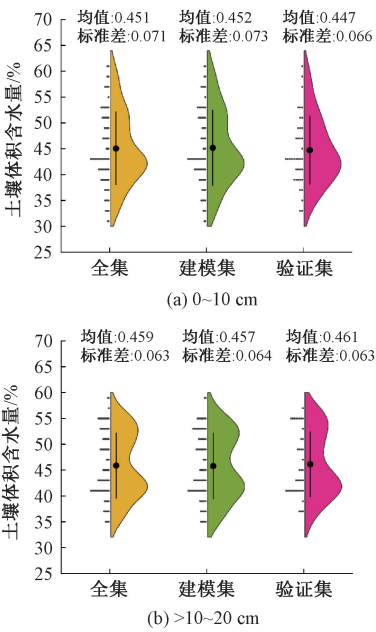


图 5 土壤含水量描述性统计

Figure 5 Descriptive statistics of soil water conte

2.3 模型构建

本研究基于随机森林算法,通过调整输入的自变量因子构建 8 种土壤水分反演模型,各模型的参数设置均如表 2 所示。此外,为便于分析,根据模型中的自变量因子对模型进行命名,各模型的名称、包含的自变量因子及其特征重要性见表 3。

表 2 模型的参数设置

Table 2 Parameterization of the model

参数名	参数值
内部节点分裂的最小样本数	2
叶子节点的最小样本数	1
树的最大深度	10
叶子节点的最大数量	50
决策树数量	150

特征重要性描述了因子对模型的贡献程度,在本文中,由 $TVDI$ 、 PDI 、 $f_{v_{VI}}$ 来反映模型的特征重要性。在所有模型中, $TVDI$ 的特征重要性高于 PDI ,说明 $TVDI$ 在模型中的贡献更大。而 PDI 与植被覆盖度的特征重要性关系存在变化,在大部分模型中植被覆盖度的贡献度大于 PDI 。为了更清晰地对比不同植被覆盖度参数的特征重要性关系,建立包含 $TVDI$ 、 PDI 和 7 种 $f_{v_{VI}}$ 参数的模型 TPF_v ,其特征重要性如表 4 所示。在 7 种 $f_{v_{VI}}$ 中,0~10 cm 深度,特征重要性最高的是 $f_{v_{RVI}}$,为 0.14,最低的是 $f_{v_{MSAVI}}$,为 0.05;>10~20 cm 深度下最高的是 $f_{v_{EVI}}$,为 0.17,最低的是 $f_{v_{MSAVI}}$,为 0.04。综合观察两种深度的结果, $f_{v_{EVI}}$ 的特征重要性最高,均达到了 0.10 以上;而 $f_{v_{MSAVI}}$ 的特征重要性最低,均不超过 0.05。

表 3 不同模型的自变量因子及其特征重要性

Table 3 Independent variable factors and their features importance of different models

模型	自变量因子	深度/ cm	<i>TVDI</i>	<i>PDI</i>	\hat{v}_{VI}
TP	<i>TVDI</i> 、 <i>PDI</i>	0~10	0.521	0.479	
		>10~20	0.514	0.486	
TP _{SAVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{SAVI}	0~10	0.416	0.215	0.369
		>10~20	0.453	0.238	0.309
TP _{RVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{RVI}	0~10	0.345	0.255	0.400
		>10~20	0.396	0.307	0.296
TP _{OSAVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{OSAVI}	0~10	0.386	0.246	0.368
		>10~20	0.411	0.259	0.330
TP _{mSAVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{mSAVI}	0~10	0.378	0.424	0.198
		>10~20	0.391	0.373	0.237
TP _{MSAVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{MSAVI}	0~10	0.472	0.250	0.278
		>10~20	0.480	0.282	0.238
TP _{EVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{EVI}	0~10	0.411	0.274	0.315
		>10~20	0.383	0.266	0.351
TP _{NDVI}	<i>TVDI</i> 、 <i>PDI</i> 、 \hat{v}_{NDVI}	0~10	0.366	0.260	0.373
		>10~20	0.377	0.326	0.296

表 4 TPFv 模型各因子特征重要性

Table 4 Feature importance of factors in the TPFv model

深度/cm	<i>TVDI</i>	<i>PDI</i>	\hat{v}_{SAVI}	\hat{v}_{RVI}	\hat{v}_{OSAVI}	\hat{v}_{mSAVI}	\hat{v}_{MSAVI}	\hat{v}_{EVI}	\hat{v}_{NDVI}
0~10	0.19	0.10	0.08	0.14	0.12	0.07	0.05	0.13	0.12
10~20	0.20	0.09	0.09	0.09	0.14	0.09	0.04	0.17	0.09

表 5 模型精度评价

Table 5 Evaluation of model accuracy

模型	深度/cm	R^2	<i>RMSE</i> /%	<i>MAE</i> /%	<i>MSE</i> /%
TP	0~10	0.606	4.5	3.3	0.21
	>10~20	0.670	4.1	2.8	0.17
TP _{SAVI}	0~10	0.649	4.5	3.0	0.19
	>10~20	0.759	3.7	2.5	0.14
TP _{RVI}	0~10	0.724	4.1	2.6	0.16
	>10~20	0.772	3.6	2.4	0.13
TP _{OSAVI}	0~10	0.749	3.8	2.6	0.15
	>10~20	0.828	3.3	2.2	0.11
TP _{mSAVI}	0~10	0.748	3.9	2.6	0.15
	>10~20	0.744	3.7	2.4	0.14
TP _{MSAVI}	0~10	0.611	4.6	3.2	0.20
	>10~20	0.703	3.9	2.7	0.15
TP _{EVI}	0~10	0.736	4.0	2.6	0.16
	>10~20	0.705	4.0	2.4	0.16
TP _{NDVI}	0~10	0.745	3.9	2.6	0.15
	>10~20	0.760	3.7	2.5	0.13

RMSE 升高 0.1 百分点、降低 0.2 百分点, *MAE* 降低 0.1 百分点、0.1 百分点, *MSE* 降低 0.01 百分点、0.02 百分点。

综上所述,TP_{OSAVI} 模型的拟合效果最好,精度最

2.4 模型精度评价

模型的精度评价结果见表 5。0~10 cm 深度下,8 种模型的 R^2 按从大到小排列为 TP_{OSAVI}、TP_{mSAVI}、TP_{NDVI}、TP_{EVI}、TP_{RVI}、TP_{SAVI}、TP_{MSAVI}、TP;10~20 cm 深度下,8 种模型的 R^2 按从大到小排列为 TP_{OSAVI}、TP_{RVI}、TP_{NDVI}、TP_{SAVI}、TP_{mSAVI}、TP_{EVI}、TP_{MSAVI}、TP。综合考虑 4 种评价指标,7 种引入植被覆盖度的模型精度均较 TP 模型的精度有一定程度的提升。其中,最优模型为 TP_{OSAVI},在 0~10 cm 和>10~20 cm 深度时, R^2 分别为 0.749、0.828,较 TP 模型分别提高 0.143、0.158, *RMSE* 降低 0.7 百分点、0.8 百分点, *MAE* 降低 0.7 百分点、0.6 百分点, *MSE* 降低 0.06 百分点、0.06 百分点。此外,大部分模型在>10~20 cm 深度时的精度高于 0~10 cm,且 TP_{OSAVI} 在该深度下的 R^2 明显高于其他模型; *RMSE*、*MAE*、*MSE* 低于其他模型,表明该模型的相关性强、偏差小、精度高。反演结果最差的模型为 TP_{MSAVI},在两种深度时,其 R^2 较 TP 模型分别提高 0.005、0.033,

高,能较为准确地反映土壤的含水量状况。因此,本研究选择 TP_{OSAVI} 模型对实验区的土壤水分空间分布情况进行分析。

2.5 空间分布

实验区的土壤水分空间分布情况见图 6。总体来看,土壤水分较大,湿度较高,与数据采集前实验区曾进行灌溉的实际情况相符。0~10 cm 深度下,土壤水分呈现出西高东低的特征;>10~20 cm 深度时,土壤水分的空间分布则没有明显规律,仅东北侧土壤含水量稍高。农田土壤水分面积统计结果见表 6,其分布特点与实测土壤水分全集的描述性统计结果有一定的相似性,0~10 cm 深度时,土壤水分集中分布在 40%~50%,占总面积的 39.6%;>10~20 cm 深度时,土壤水分仍集中分布在 40%~50%,占总面积的 37.9%。此外,部分区域 0~10 cm 的土壤水分较大,而另一部分区域>10~20 cm 的土壤水分较大。这种差异可能是由于实验区内不同区域近期灌溉的时间、程度不同,因此水分的蒸发、下渗等情况存在差异,导致两种深度下土壤水分的大小关系出现波动,且呈现出空间分布特点不一致的情况。

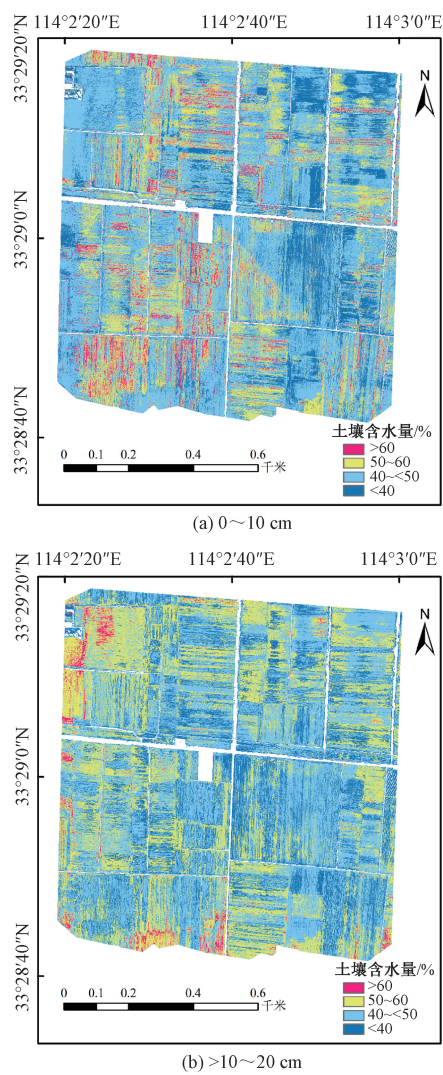


图 6 实验区土壤水分空间分布

Figure 6 Spatial distribution of soil moisture in the experimental area

表 6 土壤水分面积统计

Table 6 Soil moisture content area statistics

深度/cm	土壤含水量/%	土壤面积占比/%
0~10	<40	28.3
	40~<50	39.6
	50~60	25.9
	>60	6.2
>10~20	<40	24.5
	40~<50	37.9
	50~60	33.1
	>60	4.5

3 讨论

随机森林算法是一种集成学习的思想,它基于有放回的随机抽样来获得数据输入决策树,并通过所有决策树的均值生成最终的输出结果,能很好地模拟相关参数与土壤水分之间复杂的非线性关系。

本文在两个干旱指数的基础上引入了由不同植被指数估算的植被覆盖度,基于随机森林算法建立土壤水分反演模型。研究表明,引入植被覆盖度的模型精度均高于未引入植被覆盖度的 TP 模型精度,说明引入植被覆盖度能有效提高土壤水分反演模型的精度,这也与张智韬等^[20]的研究结果相似。7 种引入植被覆盖度的模型中,通过对 4 种评价指标的综合考量得到最优的模型为 TP_{OSAVI}。通过植被指数估算的植被覆盖度与真实植被覆盖度的偏差大小可能会影响模型的精度,OSAVI 是基于 SAVI 考虑了冠层背景调整因子的标准值所构建的植被指数,对超过 50% 的冠层覆盖率具有更高的敏感性,在高植被覆盖度地区估算植被覆盖度时精度较高,拟合效果较好^[16]。因此,TP_{OSAVI} 的精度高于其他模型。后续研究可以结合植被覆盖度实测数据,分析估算覆盖度与实测覆盖度之间的偏差对模型精度的影响。

TVDI 的特征重要性高于 PDI,其原因可能为本研究采用更适用于高植被覆盖度区域的梯形 EVI-T_s 特征空间计算 TVDI^[8],而 PDI 更适宜裸土及低植被地区^[15] 的土壤水分监测。实验区植被覆盖度高的区域较多,因而更适用于高植被覆盖度区域土壤水分监测的 TVDI 重要性更高。

TP、TP_{SAVI}、TP_{RVI}、TP_{OSAVI}、TP_{mSRI}、TP_{MSAVI}、TP_{NDVI} 在 10~20 cm 深度下的表现优于 0~10 cm,说明模型在深层土壤水分监测方面可能有一定的应用潜力。受实测数据限制,本文仅对 0~10 cm 及>10~20 cm 两种深度时模型的监测能力进行对比分析,后续研究应测量更深层的土壤水分数据,探究模型对不同深度下土壤水分的监测能力。

4 结论

(1)通过对 8 种土壤水分反演模型的精度评价指标进行对比分析,发现引入植被覆盖度的 7 种模型的精度高于未引入植被覆盖度的 TP 模型。引入植被覆盖度能有效提高模型的精度。

(2)综合考虑 4 种评价指标,最优模型 TP_{OSAVI} 较 TP 模型有较大的提升,在 0~10 cm 和>10~20 cm 深度时,R² 较 TP 模型分别提高 0.143、0.158, RMSE 降低 0.7 百分点、0.8 百分点, MAE 降低 0.7 百分点、0.6 百分点, MSE 降低 0.06 百分点、0.06 百分点。

(3)对于本实验区,同一种模型在不同深度下的适用性不同,大部分模型对更深层的土壤水分反演具有更高的精度。

参考文献:

[1] 冯珊珊,梁雪映,樊风雷,等. 基于无人机多光谱数据的农田土壤水分遥感监测[J]. 华南师范大学学报(自然科学版), 2020, 52(6): 74-81.
FENG S S, LIANG X Y, FAN F L, et al. Monitoring of farmland soil moisture based on unmanned aerial vehicle multispectral data[J]. Journal of South China Normal University (Natural Science Edition), 2020, 52(6): 74-81.

[2] 李德仁,李明. 无人机遥感系统的研究进展与应用前景[J]. 武汉大学学报(信息科学版), 2014, 39(5): 505-513, 540.
LI D R, LI M. Research advance and application prospect of unmanned aerial vehicle remote sensing system[J]. Geomatics and Information Science of Wuhan University, 2014, 39(5): 505-513, 540.

[3] 金伟,葛宏立,杜华强,等. 无人机遥感发展与应用概况[J]. 遥感信息, 2009, 24(1): 88-92.
JIN W, GE H L, DU H Q, et al. A review on unmanned aerial vehicle remote sensing and its application[J]. Remote Sensing Information, 2009, 24(1): 88-92.

[4] 马仪,黄组桂,贾江栋,等. 基于无人机-卫星遥感升尺度的土壤水分监测模型研究[J]. 农业机械学报, 2023, 54(6): 307-318.
MA Y, HUANG Z G, JIA J D, et al. Soil moisture monitoring model based on UAV-satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 307-318.

[5] 葛少青,张剑,孙文,等. 三种干旱指数在干旱区沼泽湿地土壤水分遥感反演中的应用[J]. 生态学报, 2018, 38(7): 2299-2307.
GE S Q, ZHANG J, SUN W, et al. Application of three drought indexes in soil moisture inversion using remote sensing in marsh wetlands of arid area[J]. Acta Ecologica Sinica, 2018, 38(7): 2299-2307.

[6] 蔡亮红,丁建丽,魏阳. 基于多源数据的土壤水分反演及空间分异格局研究[J]. 土壤学报, 2017, 54(5): 1057-1067.
CAI L H, DING J L, WEI Y. Spatial variation and inversion of soil moisture based on multi-source data[J]. Acta Pedologica Sinica, 2017, 54(5): 1057-1067.

[7] 张文江,陆其峰,高志强,等. 基于水分距平指数的2006年四川盆地东部特大干旱遥感响应分析[J]. 中国科学: D辑 地球科学, 2008, 38(2): 251-260.
ZHANG W J, LU Q F, GAO Z Q, et al. Remote sensing response analysis of the severe drought in eastern Sichuan Basin in 2006 based on moisture anomaly index[J]. Science in China: Series D Earth Sciences, 2008, 38(2): 251-260.

[8] 高磊,覃志豪,卢丽萍. 基于植被指数和地表温度特征空间的农业干旱监测模型研究综述[J]. 国土资源遥感, 2007, 19(3): 1-7.
GAO L, QIN Z H, LU L P. An overview on agricultural drought monitoring models based on vegetation index and surface temperature feature space[J]. Remote Sensing for Land & Resources, 2007, 19(3): 1-7.

[9] 杨志辉,赵军,朱国锋,等. 顾及植被覆盖影响的石羊河流域土壤水分遥感估算及空间格局分析[J]. 生态学报, 2020, 40(23): 8826-8837.
YANG Z H, ZHAO J, ZHU G F, et al. Remote sensing estimation and spatial pattern analysis of soil moisture in Shiyang River Basin considering the influence of vegetation cover[J]. Acta Ecologica Sinica, 2020, 40(23): 8826-8837.

[10] GHULAM A, QIN Q, TEYIP T, et al. Modified perpendicular drought index (MPDI): a real-time drought monitoring method[J]. Photogrammetry and Remote Sensing, 2007, 62(2): 150-164.

[11] 朱燕香,潘剑君,白浩然,等. 基于 Sentinel-2A 影像的 OPTRAM 模型及其改进模型的土壤水分估算研究[J]. 南京农业大学学报, 2020, 43(4): 682-689.
ZHU Y X, PAN J J, BAI H R, et al. Soil moisture estimation with the OPTRAM model and its improved model based on Sentinel-2A data[J]. Journal of Nanjing Agricultural University, 2020, 43(4): 682-689.

[12] PRICE J C. Using spatial context in satellite data to infer regional scale evapotranspiration[J]. IEEE Transactions on Geoscience and Remote Sensing, 1990, 28(5): 940-948.

[13] 王正兴,刘闯,ALFREDO H. 植被指数研究进展: 从 AVHRR-NDVI 到 MODIS-EVI[J]. 生态学报, 2003, 23(5): 979-987.
WANG Z X, LIU C, ALFREDO H. From AVHRR-NDVI to MODIS-EVI: advances in vegetation index research[J]. Acta Ecologica Sinica, 2003, 23(5): 979-987.

[14] 杨曦,武建军,闫峰,等. 基于地表温度-植被指数特征空间的区域土壤干湿状况[J]. 生态学报, 2009, 29(3): 1205-1216.
YANG X, WU J J, YAN F, et al. Assessment of regional soil moisture status based on characteristics of surface temperature/vegetation index space[J]. Acta Ecologica Sinica, 2009, 29(3): 1205-1216.

[15] 冯海霞,秦其明,李滨勇,等. 基于 SWIR-Red 光谱特征空间的农田干旱监测新方法[J]. 光谱学与光谱分析, 2011, 31(11): 3069-3073.
FENG H X, QIN Q M, LI B Y, et al. The new method monitoring agricultural drought based on SWIR-red spectrum feature space[J]. Spectroscopy and Spectral Analysis, 2011, 31(11): 3069-3073.

[16] 丁艳玲. 植被覆盖度遥感估算及其真实性检验研究

[D]. 北京: 中国科学院大学, 2015.

DING Y L. Study on remote sensing estimation of vegetation coverage and its authenticity test[D]. Beijing: University of Chinese Academy of Sciences, 2015.

[17] 敖登, 杨佳慧, 丁维婷, 等. 54 种植被指数研究进展综述[J]. 安徽农业科学, 2023, 51(1): 13-21, 28.

AO D, YANG J H, DING W T, et al. Review of 54 vegetation indices [J]. Journal of Anhui Agricultural Sciences, 2023, 51(1): 13-21, 28.

[18] 方匡南, 吴见彬, 朱建平, 等. 随机森林方法研究综述[J]. 统计与信息论坛, 2011, 26(3): 32-38.

FANG K N, WU J B, ZHU J P, et al. A review of technologies on random forests [J]. Statistics & Information Forum, 2011, 26(3): 32-38.

[19] 李爱民, 王海隆, 许有成. 优化随机森林算法的城市湖泊 DOC 质量浓度遥感反演[J]. 郑州大学学报(工学版), 2022, 43(6): 90-96.

LI A M, WANG H L, XU Y C. Remote sensing retrieval of urban lake DOC concentration based on optimized random forest algorithm[J]. Journal of Zhengzhou University (Engineering Science), 2022, 43(6): 90-96.

[20] 张智韬, 许崇豪, 谭丞轩, 等. 覆盖度对无人机热红外遥感反演玉米土壤含水率的影响[J]. 农业机械学报, 2019, 50(8): 213-225.

ZHANG Z T, XU C H, TAN C X, et al. Influence of coverage on soil moisture content of field corn inversed from thermal infrared remote sensing of UAV[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 213-225.

Soil Moisture Inversion for Winter Wheat Field Based on UAV
Multispectral and Thermal Infrared Data

ZHANG Chengcai¹, HOU Jiatong¹, WANG Rui¹, JIANG Mingliang^{1,2}, ZHU Xingxing¹

(1. School of Water Conservancy and Transportation, Zhengzhou University, Zhengzhou 450001, China; 2. Institute of Farmland Irrigation of CAAS, Xinxiang 453002, China)

Abstract: The introduction of fractional vegetation cover could improve the accuracy of soil moisture inversion model to some extent, but most studies estimated fractional vegetation cover based on normalized difference vegetation index *NDVI*, and without in-depth study on the impact of vegetation coverage based on other vegetation indices on the model. Therefore, taking the winter wheat planting area in Xiping County, Zhumadian City, Henan Province as the experimental area, based on the UAV platform with high resolution and strong mobility, the multi-spectral and TIR imaging apparatus were equipped to carry out the soil moisture inversion research of winter wheat covered surface, and to explore the changes of model accuracy after introducing different fractional vegetation cover parameters, so as to make up for the limitations of soil moisture monitoring caused by the low resolution and poor timeliness of satellite remote sensing images. The two drought indices of temperature vegetation dryness index *TVDI* and perpendicular drought index *PDI* were combined with the parameters of fractional vegetation cover estimated through seven vegetation indices, respectively, and seven soil moisture inversion models were constructed based on the random forest algorithm, and the spatial distribution of soil moisture in the experimental area was analyzed according to the inversion results of the optimal model. At the same time, the soil moisture inversion model TP model, which could integrateed *TVDI* and *PDI* indices and without introducing fractional vegetation cover, was built as the control group. The results showed that the R^2 of the TP model was 0.606, 0.670, the root mean square error *RMSE* was 0.045、0.041 for the depths of 0 to10 cm and >10 to 20 cm respectively. The accuracy of the seven models introducing fractional vegetation cover was improved to some extent compared with that of the TP model. Among them, the R^2 of the optimal model TP_{OSAVI} was improved by 0.143, 0.158, the *RMSE* was reduced by 0.7 percentage points, 0.8 percentage points respectively, compared with the TP model. It showed that the introduction of fractional vegetation cover based on the drought indices could improve the accuracy of model inversion and different fractional vegetation cover had different effects on the accuracy of the model.

Keywords: soil moisture retrieval; UAV remote; multispectral; thermal infrared; random forest; drought indices; fractional vegetation cover