

基于 GF-1 卫星遥感的河套灌区土壤含水率反演模型研究

姚一飞^{1,2} 王爽^{1,2} 张珺锐^{1,2} 黄小鱼^{1,2} 陈策^{1,2} 张智韬^{1,2}

(1. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;

2. 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: 为探究植被覆盖条件下 GF-1 卫星反演农田土壤含水率的可行性,以河套灌区解放闸灌域沙壕渠为研究区,采用 GF-1 卫星遥感影像作为数据源,通过全子集筛选法确定不同土壤深度下光谱指数的最优自变量组合,并分别采用多元线性回归(MLR)、BP 神经网络(BPNN)、支持向量机(SVM)3 种算法,构建不同深度下土壤含水率反演模型。结果表明,全子集筛选后模型反演精度有较大提升,且过拟合现象减弱;植被覆盖条件下各深度土壤含水率敏感程度从大到小依次为 0~40 cm、0~60 cm、20~40 cm、0~20 cm、40~60 cm;植被覆盖条件下各模型对土壤含水率反演能力由强到弱依次为 BPNN、SVM、MLR;筛选后 BPNN 在深度 0~40 cm 下的建模集和验证集 R^2_{adj} 均能达到 0.50 以上, RMSE 在 0.02% 以内。研究结果可为植被覆盖条件下利用 GF-1 卫星监测农田土壤含水率提供参考。

关键词: 土壤含水率; 遥感; 反演; GF-1 卫星; 全子集筛选; 光谱指数

中图分类号: S152.7; TP79

文献标识码: A

文章编号: 1000-1298(2022)09-0239-13

OSID:



Inversion Model of Soil Moisture in Hetao Irrigation District Based on GF-1 Satellite Remote Sensing

YAO Yifei^{1,2} WANG Shuang^{1,2} ZHANG Junrui^{1,2} HUANG Xiaoyu^{1,2} CHEN Ce^{1,2} ZHANG Zhitao^{1,2}

(1. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. The Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: In order to explore the feasibility of GF-1 satellite inversion of farmland soil moisture content (SMC) under the condition of vegetation coverage, taking Shahaoqu District of Hetao Irrigation Area as study area, and GF-1 satellite remote sensing images as the data source. Simultaneously, the soil moisture content data were collected with various depths at 0~20 cm, 20~40 cm, 40~60 cm, 0~40 cm, and 0~60 cm. Then a set of independent variables, including four bands and 15 spectral indices were obtained based on the GF-1 data, and the full subset selection was used to select the optimal combination of independent variables at five depths. Based on these, the combinations before and after full subset selection were used to build soil moisture content inversion models(multiple linear regression, MLR; back propagation neural network, BPNN; support vector machines, SVM) at five depths in the vegetated area, and evaluate the sensitivity of GF-1 to SMC at different depths and the inversion capability of the models. The model performance was assessed by using adjusted coefficient of determination (R^2_{adj}) and root mean square error (RMSE). The results showed that the model inversion accuracy was greatly improved after the full subset selection, and the over-fitting phenomenon can be reduced. The sensitivity of GF-1 to the SMC at different depths under vegetation coverage was ordered from the largest to the smallest as follows: 0~40 cm, 0~60 cm, 20~40 cm, 0~20 cm, and 40~60 cm. The SMC inversion capabilities of all the three models under vegetation coverage ordered from the largest to the smallest were as follows: BPNN, SVM, and MLR. After the full subset selection, the R^2_{adj} of the modeling set and verification set of BPNN at depth of 0~40 cm can reach more than 0.50, and the RMSE was within 0.02%. The research result can provide a reference for using GF-1 satellite to monitor SMC of farmland under vegetation coverage.

Key words: soil moisture content; remote sensing; inversion; GF-1 satellite; full subset selection; spectral index

收稿日期: 2021-09-17 修回日期: 2021-11-13

基金项目: 国家重点研发计划项目(2017YFC0403302)和国家自然科学基金项目(41804029,51979232,51979234)

作者简介: 姚一飞(1989—),男,副教授,博士,主要从事遥感技术在节水灌溉及水资源高效利用中的应用研究,E-mail: yifeiyao@163.com

0 引言

土壤水分是决定植被生长、农作物生产、区域生态环境稳定的关键因素,其动态变化趋势影响着各种生物的生存和发展。因此,准确、及时地反演土壤水分具有重要意义。遥感监测土壤含水率技术克服了传统田间实测法低效率、高成本、单点测量的缺点^[1],是大范围监测土壤含水率时空分布和动态变化的有效手段^[2],在精准农业中具有广阔应用前景^[3]。

利用光学遥感监测裸土土壤含水率的可行性已被诸多学者验证^[4-6]。但在现实情况下农田土壤常被不同作物覆盖,仅监测裸土土壤含水率无法满足农田灌溉的需要。因此,部分学者提出采用构造不同光谱指数可以定量监测植被生长状况及其覆盖下的土壤含水率。文献[7]利用地表温度与归一化植被指数(NDVI)之间的比例关系对地表的干旱程度开展动态监测;土壤背景对用于计算植被指数的反射率具有不同程度的影响,HUETE^[8]基于 NDVI 大量观测数据提出了土壤调节植被指数(SAVI)来减少土壤背景的影响^[9],而基于 SAVI 发展了多种新的指数,包括:土壤调节植被指数 2(SAVI2)^[10]、转换型土壤调节植被指数(TSAVI)、调整转换型土壤调节植被指数(ATSAVI)^[11]等。夏权等^[12]利用资源三号卫星的多光谱数据,建立增强型植被指数(EVI)反演土壤水分含量数学模型;吴春雷等^[13]针对垂直干旱指数(PDI)在农田植被区土壤湿度监测精度降低问题引入垂直植被指数(PVI)进行调整;蔡亮红等^[14]利用 Landsat8 OLI 遥感数据,将短波红外波段引入到可见光-近红外植被指数中,获得了较好的土壤水分反演结果;WEST 等^[15]研究发现干旱条件下 NDVI 能较好反映土壤水分状况,并且 Sentinel-2 卫星反演效果优于 Landsat8,在土壤水分监测中应用潜力大;同样利用 Landsat 卫星,

NATALIE 等^[16]使用归一化红外指数(NDII)和 NDVI 分析湿地土壤水分的时空趋势,REZA 等^[17]使用归一化差值含水指数(NDMI)对于干旱半干旱地区的土壤表面水分进行了测量。GF-1 作为我国重要的多光谱卫星,在土地利用分类^[18]、船舶探测^[19]、农作物光合有效辐射吸收比率估算^[20]、气溶胶光学厚度反演^[21]、冰川识别^[22]方面已开展广泛研究,但目前用于植被覆盖条件下土壤水分的反演研究较少。

本文以河套灌区解放闸灌域沙壕渠为研究区,以 GF-1 卫星遥感影像为数据源,并同步采集不同深度土壤含水率,利用全子集筛选法确定不同深度下光谱指数的最优自变量组合,采用多元线性回归、BP 神经网络和支持向量机 3 种算法,构建不同深度下土壤含水率反演模型,探究 GF-1 号卫星反演植被覆盖条件下农田土壤含水率的可行性,以期在全灌区干旱监测与预警提供技术依据。

1 数据集建立与反演模型构建

1.1 研究区概况

内蒙古河套灌区是我国设计灌溉面积最大的灌区^[23]。位于内蒙古自治区西部的巴彦淖尔盟,东西长约 250 km,南北宽约 50 km,总灌溉面积约为 5 740 km²。灌区是典型的温带大陆性气候,降雨量少、蒸发量大,地处干旱的西北高原,但其区域内遍布人工水系,年引黄河水量高达 50 亿 m³,形成了独特的干旱区“绿洲”生态,是国家和自治区重要的商品粮、油生产基地。保障河套灌区农业可持续发展对我国旱区农业生产生活意义重大,随节水改造工程的实施,河套灌区面临指令性的节水形势。

解放闸灌域是河套灌区的第二大灌域,位于河套灌区西部(图 1a),灌溉面积 1 420 km²,灌溉水主要来源于过境的黄河水,年均降水量约为 140 mm,




图 1 内蒙古河套灌区解放闸灌域沙壕渠地理位置图与样本点分布图
Fig.1 Geographical location map of Jiefangzha Irrigation Area in Inner Mongolia Hetao Irrigation District and sample points distribution

年均蒸发量约为 2 000 mm。解放闸灌域地形较为平缓,地势由东南向西微度倾斜^[24],平均坡度为 0.2%,其平坦的地形地势使排水系统能力降低,加之地下水埋深较浅,为高效地利用水资源,优化灌溉制度,有必要进行大面积土壤含水率的监测。根据实际试验条件,本次选取河套灌区解放闸灌域沙壕渠试验站为研究区。

1.2 土壤样本采集与处理

7—9 月是研究解放闸灌域植被覆盖区域的最佳时期,该时段内灌域的主要作物葵花、玉米(占有作物面积 80%)等都处于生长旺盛期,9 月下旬灌域作物均已成熟,等待收割^[25],因此选择作物生长旺盛、植被信息丰富的 2019 年 7 月 15—25 日作为研究时段。采用手持 GPS 定位,利用打土钻取样,且记录采样点的植株高度、耕作状况、植被种类等,综合考虑了不同土地利用方式、种植结构、灌溉方式等情况,以及 GF-1 号卫星分辨率为 16 m,在河套灌区沙壕渠共布置了 120 个 16 m×16 m 采样点,并尽量保证点的均匀性。采样点分布情况见图 1b。在植被覆盖情况下,土壤水分胁迫将影响作物根系的生长,导致作物光谱特征及作物长势明显变化,卫星遥感监测是依据解译作物生长状况及作物长势进而判断根系主要活动层所在土壤深度的含水率,故采用五点取样法,根据研究区域该时段的作物主根系深度及相关研究成果^[26-28],在深度 0~60 cm 范围内每隔 20 cm 分层取样,将采取的土样充分混合后得到具有代表性的样品。

1.2.1 土壤含水率测定

将野外采集到的各深度的 120 个土样快速装入已知质量的干燥铝盒中,贴好标签并密封后称量。采集工作完成后将封装好的土样托运回西北农林科技大学旱区农业水土工程教育部重点实验室进行后续处理,经 105℃,24 h 恒温处理后,取出铝盒称量。土壤质量含水率 θ_m 计算式为

$$\theta_m = \frac{W_1 - W_2}{W_2 - W_3} \times 100\% \tag{1}$$

式中 W_1 ——湿土加铝盒质量
 W_2 ——干土加铝盒质量
 W_3 ——空铝盒质量

结合地面植被情况,剔除小麦收割后、裸土以及存在明显粗误差的采样数据(由于试验测量过程中或记录相关数据时错读、错记造成含水率为负),剩余 100 余个土壤样本用于本次 7 月植被覆盖条件下的灌区土壤含水率反演研究。

1.2.2 土壤含水率统计特征

选取 0~20 cm、20~40 cm、40~60 cm、0~

40 cm 和 0~60 cm 5 个深度土壤含水率为研究对象,其中 0~40 cm 和 0~60 cm 含水率为对应深度内实测数据的平均值。不同深度数据集按照土壤含水率降序或升序排列,采用每隔 2 个样本提取 1 个样本作为验证集的方法,使得建模集与验证集样本数比例近似为 2:1,以期实现建模样本和验证样本范围一致且分布均匀。土壤含水率统计特征见图 2 和表 1。




图2 土壤含水率统计箱型图
Fig.2 Box plot about descriptive statistics of soil moisture content

表1 土壤含水率统计特征

Tab.1 Statistical characteristics of soil moisture content

深度/ cm	类型	数目/ 个	最小 值/%	最大 值/%	平均 值/%	标准 误差/%	变异系 数/%
0~20	总体	101	16.53	31.34	24.46	0.27	11.22
	建模集	67	16.53	31.34	24.54	0.36	12.01
	验证集	34	18.09	28.16	24.29	0.39	9.40
20~40	总体	107	14.78	34.95	26.48	0.36	13.92
	建模集	71	14.78	32.84	26.45	0.43	13.60
	验证集	36	15.56	34.95	26.55	0.64	14.54
40~60	总体	108	21.30	35.11	29.21	0.28	10.14
	建模集	72	21.30	33.72	29.03	0.33	9.59
	验证集	36	22.30	35.11	29.58	0.54	11.00
0~40	总体	106	14.61	33.02	25.51	0.34	13.57
	建模集	70	14.96	31.32	25.55	0.39	12.87
	验证集	36	14.61	33.02	25.46	0.62	14.60
0~60	总体	105	17.94	32.85	26.70	0.29	11.09
	建模集	70	17.98	32.85	26.53	0.35	11.18
	验证集	35	17.94	31.34	27.05	0.49	10.80

0~20 cm、20~40 cm 和 40~60 cm 3 个深度土壤含水率平均值分别为 24.46%、26.48% 和 29.21%,标准误差分别为 0.27%、0.36%、0.28%,表明不同深度的土壤含水率存在显著差异,土壤含水率随着土壤深度而增加,与文献[29-30]研究结果一致。变异系数是表征土壤含水率变化幅度的指标,变异系数越小,土壤含水率越稳定,深层(40~60 cm)土壤含水率变异系数相对最小,主要原因是深层土壤受光照辐射、降雨量以及土壤蒸散发等外

界环境因素的影响较小^[31]。

各个深度下总体与建模集、验证集的土壤含水率变化范围和统计分布(平均值、中位数、标准差、变异系数)基本一致,确保了样本的代表性,同时也避免了建模和验证中的估计偏差。

1.3 遥感影像选取与处理

采用 GF-1 卫星遥感影像为数据源,空间分辨率 16 m,共计 4 个波段,重访时间 2 d,卫星影像的成像时间为 2019 年 7 月 27 日,与实测数据日期基本同步。卫星影像数据由中国资源卫星应用中心下载获得(<http://www.cresda.com/CN/>)。对下载的影像经过几何精校正、辐射校正、大气校正预处理后用于后续土壤含水率反演。卫星 4 个波段范围分别为 0.45 ~ 0.52 μm、0.52 ~ 0.59 μm、0.63 ~ 0.69 μm、0.77 ~ 0.89 μm。

1.4 光谱指数提取与筛选

1.4.1 光谱指数选取

选取空间分辨率为 16 m × 16 m 的 GF-1 卫星遥感影像,仅用 4 个波段反射率提取土壤水分信息并分析其相关性有一定局限性,考虑到 7 月为灌区内作物生长发育的关键时期,植被覆盖率较高,可利用 GF-1 卫星数据的 4 个波段反射率计算相关光谱指数建立遥感图像与土壤含水率的定量关系。

本文共选取包括土壤亮度指数(BI)^[32]、盐分指数(SI)^[33]、盐分指数 1(SI1)、盐分指数 2(SI2)、盐分指数 S1、盐分指数 S2、盐分指数 S6 和 EVI^[34]、差值环境植被指数(DVI)^[35]、PVI^[36]、PDI^[37]、SAVI2、土壤大气抗阻植被指数 2(SARVI2)^[38]、TSAVI、ATSAVI 在内的光谱指数共 15 个。其中,EVI、DVI 等是光学卫星反演土壤水分的常用植被指数,同时,由于研究区域为我国典型的盐渍化地区,与正常情况相比,当作物受到水分胁迫和盐分胁迫时,其状态的改变会在光谱特征上有所体现^[39]。当研究区域内土壤水分在时空上具有一定动态变化时,土壤水分和盐分对土壤反射光谱有相似的影响^[40]。故在此基础上,选取 6 个盐分指数共同用于本次植被覆盖条件下农田土壤含水率的反演。

1.4.2 全子集筛选

全子集筛选法是遍历自变量全集中所有可能的组合方式,通过最小二乘法对每种变量组合进行拟合,并从中选取效果最佳的模型。主要计算过程如下:

假设回归分析中有 N 个自变量, N 中任意 M ($1 \leq M \leq N$) 个自变量分别与因变量 Y 建立回归方程;拟合 1 ~ N 个预测变量的模型,不同数目模型有 C_N^M 种排列组合方式;在 1 ~ N 个模型中,根据调整

后决定系数(Adjusted coefficient of determination, R_{adj}^2)最大准则来选择 N 个最优模型;以 R_{adj}^2 、均方根误差(Root mean square error, RMSE)、赤池信息准则(Akaike information criterion, AIC)、贝叶斯信息准则(Bayesian information criterion, BIC)为依据,从 N 个模型中选择最优的模型^[41]。随着自变量个数的增加,全子集运行效率降低^[42],结合前人研究成果^[43-45],综合考虑全子集效果和计算量问题, M 取 2 ~ 6。

其中 R_{adj}^2 考虑了自变量个数和样本个数的影响,随着模型自变量的增加,其值不会必然增加,减轻了过拟合现象^[46];RMSE 为评价模型拟合误差的指标,其值越小表明模型拟合误差越小;AIC 和 BIC 均为衡量模型拟合优度的指标,其数值越小表明模型越能以更少的自变量解释因变量^[47]。

1.5 回归模型构建

1.5.1 多元线性回归模型

多元线性回归(Multiple linear regression, MLR)是一元线性回归的扩展,可分为单因变量和多因变量 2 种类型^[48]。

当因变量受多个自变量影响时,可通过一般线性回归模型表示为

$$Y = \beta X + \varepsilon \tag{2}$$

式中 X ——自变量 β ——自变量系数

ε ——满足正态独立同分布的随机误差项

与一元线性回归类似,参数 β 估计是在误差平方和最小的前提下,用普通最小二乘法求解^[49]。利用 Matlab 软件进行多元线性回归的建模与验证。

1.5.2 BP 神经网络模型

BP 神经网络(Back propagation neural network, BPNN)是目前应用较为广泛、相对通俗易懂的神经网络模型。该模型的非线性映射能力较强,能够根据输出结果与实测值之间的误差调节系统内部的参数,并依据精度要求反复进行信号前向传播和误差反向传播的操作,最终得到输出结果。该模型拓扑结构由输入层、隐藏层、输出层构成。输入层为不同深度下全变量(即 4 个波段反射率和 15 个光谱指数)及经过全子集筛选后的最优变量组合;隐含层的网络层数设置为 2,采用双曲正切激活函数;输出层为土壤含水率,采用恒等激活函数;目标误差为 0.001。利用 Matlab 软件进行 BP 神经网络建模与验证。

1.5.3 支持向量机模型

支持向量机(Support vector machines, SVM)是一种基于分类边界的方法^[50],可扩展用于回归分析。其能够根据有限的样本信息,平衡模型的复杂

性和学习能力,找到最优解,在处理高维数据集、小样本和非线性问题中都具有良好表现。SVM 在结构风险最小化原理的基础上,利用核函数映射的方法,通过非线性变换,将低维空间的点映射到高维空间,使它们成为线性可分,建立线性模型以此求解非线性问题,很大程度上克服了“离散值多”和“过学习”等问题。对建模精度影响最大的 3 个参数是核函数类型、惩罚参数 C 、核参量 g ^[51]。

径向基核是应用最广泛的核函数,简单实用、普适性好,通过选择合适的参数,可以适用于任意分布的样本^[52]。本次支持向量机采用 RBF 核函数进行计算,其解析式为

$$K(\boldsymbol{x},\boldsymbol{x}')=\exp\left(-\frac{\|\boldsymbol{x}-\boldsymbol{x}'\|^2}{2\sigma^2}\right)\tag{3}$$

式中 $\boldsymbol{x}$ ——未知向量 $\boldsymbol{x}'$ ——支持向量
 σ ——函数宽度

利用 Matlab 软件进行支持向量机建模与验证。

1.5.4 模型精度评价指标

本研究通过调整后的决定系数 R^2_{adj} 、均方根误差 (RMSE) 对建模集和验证集的精度进行评估。其中 R^2_{adj} 可以避免不同模型因自变量数目不同而造成的误差,其值越接近 1,表明选取的波段和光谱指数组合对土壤含水率的解释能力越强,表示土壤含水率拟合效果越好;RMSE 越小,表示预测值和实测值之间的偏差越小,预测效果越好。

2 结果分析

2.1 土壤含水率与自变量相关性分析

选取 GF-1 卫星的 4 个波段反射率 (B1、B2、B3、B4) 和 15 个光谱指数,组成反演土壤含水率的自变量集。随机选取约 2/3 的样本数据组成估算数据集,对自变量集与土壤含水率的相关性进行分析,得到 Pearson 相关系数如表 2 所示。

根据相关系数检验临界值表对自变量集与土壤含水率的显著性进行检验。当自由度为 70 时,相关系数绝对值大于 0.232 即达到 0.05 显著性水平,大于 0.302 即达到 0.01 显著性水平。由表 2 可以看出,EVI、DVI、PVI、SARVI2 在深度 0~20 cm、20~40 cm、0~40 cm 和 0~60 cm 下,与土壤含水率均未表现出明显的显著性,在深度 40~60 cm 下与土壤含水率均达到 0.05 显著性水平;B3 在深度 40~60 cm 下与土壤含水率未表现出明显的显著性,与其余深度达到 0.05 显著性水平;SI、SI1 在深度 40~60 cm 下和 S6 在深度 0~20 cm 下分别与土壤含水率达到 0.05 显著性,其余自变量与各深度土壤含水率均达到 0.01 显著性水平。

表 2 波段及光谱指数与土壤含水率的 Pearson 相关系数

Tab.2 Pearson correlation coefficient of bands and spectral indices with soil moisture content

波段反射率 或光谱指数	深度/cm				
	0~20	20~40	40~60	0~40	0~60
B1	0.415	0.400	0.328	0.429	0.410
B2	0.405	0.393	0.313	0.418	0.397
B3	0.275	0.254	0.191	0.277	0.259
B4	0.478	0.572	0.545	0.559	0.555
BI	0.544	0.619	0.571	0.618	0.608
SI	0.346	0.328	0.259	0.353	0.335
SI1	0.346	0.329	0.256	0.353	0.333
SI2	0.555	0.615	0.558	0.621	0.608
S1	0.341	0.351	0.347	0.373	0.375
S2	0.353	0.364	0.354	0.385	0.386
S6	0.263	0.394	0.424	0.353	0.366
EVI	0.150	0.222	0.250	0.202	0.213
DVI	0.143	0.226	0.253	0.200	0.210
PVI	0.143	0.226	0.253	0.200	0.210
PDI	0.519	0.569	0.507	0.575	0.561
SAVI2	0.329	0.423	0.424	0.403	0.406
SARVI2	0.150	0.222	0.250	0.202	0.213
TSAVI	0.302	0.316	0.348	0.327	0.345
ATSAVI	0.341	0.365	0.315	0.376	0.360

2.2 基于全子集筛选的最优自变量组合

以建模集数据为基础,波段及光谱指数为自变量,土壤含水率为因变量,采用最小二乘法进行拟合,筛选得到 5 个深度 0~20 cm、20~40 cm、40~60 cm、0~40 cm 和 0~60 cm 下二~六元最优自变量组合,并计算最优组合下验证集的 R^2_{adj} 、RMSE、AIC 和 BIC,如表 3 所示。

从表 3 中可以看出,除 0~20 cm 外, R^2_{adj} 在其余 4 个深度下随着自变量数目的增加呈现出先增大后减小的趋势,在深度 0~20 cm、20~40 cm,自变量数目为 6 时有一定幅度的上升,这说明随着自变量数目的增加,模型拟合效果会变好,但自变量数目过多会使模型过于复杂,可能产生一定的过拟合现象;RMSE 总体上随着 R^2_{adj} 的增大而减小;AIC 和 BIC 趋势基本一致,随着自变量数目的增加,在深度 20~40 cm、40~60 cm、0~40 cm 和 0~60 cm 下呈现出先减小后增大的趋势,在深度 0~20 cm 下则呈现出不断增大的趋势。

深度 0~20 cm 下,二元的 R^2_{adj} 为 0.46,明显高于其他组合,且其 RMSE 相对最低,即误差相对较小,AIC 和 BIC 也相对最低,具有较好的拟合优度,所选自变量都通过显著性检验,因此 B2 和 S1 为该深度下的最优自变量组合;同理可得,20~40 cm 处选择 B2、B3、SI1 共 3 个自变量,40~60 cm 处选择 B1、SI2、SARVI2、SAVI2 共 4 个自变量,0~40 cm 处

表 3 基于全子集筛选的土壤含水率最佳自变量组合

Tab.3 Best independent variable combination of soil moisture content based on total subset selection						
深度/cm	数目	最佳组合变量	R^2_{adj}	RMSE/%	AIC	BIC
0 ~ 20	2	B2 ** ,S1 **	0. 46	0. 025	- 137	- 266
	3	B1 ** ,SI2 ** ,SARVI2	0. 30	0. 028	- 125	- 253
	4	B1 ** ,SI2 ** ,DVI ,SARVI2	0. 28	0. 028	- 122	- 248
	5	B1 ** ,B2 ** ,B1 ** ,SI ** ,SI1 **	0. 27	0. 029	- 120	- 244
	6	B1 ** ,B2 ** ,SI ** ,SI1 ** ,SAVI2 **	0. 31	0. 028	- 119	- 242
20 ~ 40	2	B3 * ,SI1 **	0. 48	0. 028	- 128	- 258
	3	B2 ** ,B3 * ,SI1 **	0. 57	0. 025	- 133	- 261
	4	B1 ** ,B2 ** ,SI ** ,SI1 **	0. 52	0. 026	- 127	- 254
	5	B1 ** ,B2 ** ,SI ** ,SI1 ** ,S1 **	0. 41	0. 029	- 117	- 242
	6	B1 ** ,B2 ** ,SI ** ,SI1 ** ,S1 ** ,S2 **	0. 44	0. 029	- 117	- 240
40 ~ 60	2	SI ** ,TSAVI **	0. 20	0. 029	- 124	- 253
	3	SI ** ,SARVI2 ** ,SAVI2 **	0. 51	0. 023	- 140	- 268
	4	B1 ** ,SI2 ** ,SARVI2 * ,SAVI2 **	0. 56	0. 021	- 143	- 269
	5	B1 ** ,B2 ** ,SI * ,SI1 * ,TSAVI **	0. 21	0. 029	- 118	- 243
	6	B1 ** ,B2 ** ,SI * ,SI1 * ,S1 ** ,TSAVI **	0. 20	0. 029	- 116	- 239
0 ~ 40	2	B2 ** ,S1 **	0. 50	0. 026	- 134	- 263
	3	SI ** ,SI1 ** ,S1 **	0. 61	0. 023	- 141	- 268
	4	B1 ** ,B2 ** ,SI ** ,SI1 **	0. 56	0. 024	- 135	- 261
	5	B1 ** ,B2 ** ,SI ** ,SI1 ** ,SAVI2 **	0. 41	0. 028	- 122	- 247
	6	B1 ** ,B2 ** ,SI ** ,SI1 ** ,DVI ,SAVI2 **	0. 38	0. 028	- 118	- 241
0 ~ 60	2	B2 ** ,S1 **	0. 54	0. 021	- 148	- 148
	3	B1 ** ,SI1 ** ,S1 **	0. 63	0. 019	- 154	- 154
	4	B1 ** ,B2 ** ,SI ** ,SI1 **	0. 56	0. 021	- 145	- 145
	5	B1 ** ,B2 ** ,SI ** ,SI1 ** ,SAVI2 **	0. 42	0. 024	- 133	- 133
	6	B1 ** ,B2 ** ,SI ** ,SI1 ** ,PVI ,SAVI2 **	0. 38	0. 024	- 129	- 252

注: ** 表示达到 0. 01 显著性水平; * 表示达到 0. 05 显著性水平。

选择 SI、SI1、S1 共 3 个自变量,0 ~ 60 cm 处选择 B1、SI1、S1 共 3 个自变量,作为各深度下最优自变量组合方式。

2.3 土壤含水率反演模型建立与验证

2.3.1 线性回归模型建立与验证

分别以不同深度下筛选前后的波段反射率及光谱指数为自变量,土壤含水率为因变量,运用多元线性回归模型进行不同深度下土壤含水率估算。其建模集和验证集精度如表 4 所示。

表 4 基于多元线性回归全子集筛选前后的土壤含水率反演模型

Tab.4 Inversion model of soil moisture content before and after screening of all subsets based on MLR								
深度/cm	未筛选				筛选后			
	建模集		验证集		建模集		验证集	
	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %
0 ~ 20	0.483	0.018	0.450	0.017	0.466	0.021	0.460	0.017
20 ~ 40	0.402	0.024	0.552	0.025	0.485	0.025	0.500	0.027
40 ~ 60	0.391	0.019	0.389	0.025	0.428	0.020	0.403	0.025
0 ~ 40	0.527	0.020	0.487	0.021	0.551	0.020	0.509	0.020
0 ~ 60	0.363	0.020	0.471	0.025	0.542	0.022	0.500	0.025

从表 4 可以看出,采用未筛选的多元线性回归模型中,深度 0 ~ 40 cm 下模型效果最优,建模集 R^2_{adj} 为 0. 527,明显高于其他深度,验证集 R^2_{adj} 为 0. 487,拟合效果较好,RMSE 也相对较小,分别为 0. 020% 和 0. 021%;深度 40 ~ 60 cm 下模型效果相对最差,建模集和验证集 R^2_{adj} 均低于 0. 40,模型拟合效果不佳,且验证集 RMSE 相对较大,为 0. 025%,反演误差较大;深度 0 ~ 20 cm 下模型效果仅次于深度 0 ~ 40 cm,建模集和验证集 R^2_{adj} 分别为 0. 483 和 0. 450,模型泛化性能较好,且其 RMSE 相对于其他 4 个深度最小,反演误差较小;深度 20 ~ 40 cm 拟合效果略优于深度 0 ~ 60 cm,前者建模集和验证集 R^2_{adj} 分别比后者高 0. 039、0. 081,但其 RMSE 相对于其他 4 个深度最大,反演误差偏大,2 个深度建模集 R^2_{adj} 分别低于验证集 27%、23%,说明模型稳定性较差。

采用全子集筛选后的多元线性回归模型中,深度 0 ~ 40 cm 下模型效果最优,建模集和验证集 R^2_{adj} 均高于 0. 50,拟合效果和泛化性能较好,RMSE 均为 0. 20%,反演误差相对最小;深度 0 ~ 60 cm 模型效

果仅次于 0 ~ 40 cm, 建模集和验证集 R^2_{adj} 也达到 0.50 以上, 拟合效果相当, 但其 RMSE 略高出深度 0 ~ 40 cm, 反演误差略大; 深度 40 ~ 60 cm 下模型效果相对最差, 建模集和验证集 R^2_{adj} 都低于其余 4 个深度, 拟合效果最差; 深度 0 ~ 20 cm 和 20 ~ 40 cm 模型效果相近, 深度 20 ~ 40 cm 在拟合效果上略优, 建模集和验证集 R^2_{adj} 高于前者 0.019、0.040, 但 0 ~ 20 cm 建模集和验证集 RMSE 均低于后者, 反演误差略小。

总体来说, 在多元线性回归模型中, 各深度筛选后模型拟合效果和泛化性能优于筛选前, 且筛选后模型稳定性更强。全子集多元线性回归模型在不同深度土壤含水率的反演效果由好到差依次为: 0 ~ 40 cm、0 ~ 60 cm、20 ~ 40 cm、0 ~ 20 cm、40 ~ 60 cm。

2.3.2 BP 神经网络模型建立与验证

分别以不同深度下筛选前后的波段反射率及光谱指数为自变量, 土壤含水率为因变量, 运用 BP 神经网络模型进行不同深度下土壤含水率估算。其建模集和验证集精度如表 5 所示。

表 5 基于 BP 神经网络全子集筛选前后的土壤含水率反演模型

Tab.5 Inversion model of soil moisture content before and after screening of all subsets based on BPNN

深度/cm	未筛选				筛选后			
	建模集		验证集		建模集		验证集	
	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %
0 ~ 20	0.514	0.021	0.474	0.017	0.495	0.021	0.472	0.017
20 ~ 40	0.538	0.024	0.550	0.026	0.503	0.025	0.502	0.027
40 ~ 60	0.493	0.020	0.429	0.025	0.453	0.021	0.431	0.025
0 ~ 40	0.521	0.020	0.472	0.022	0.559	0.020	0.514	0.020
0 ~ 60	0.565	0.023	0.455	0.026	0.559	0.022	0.517	0.025

从表 5 可以看出, 采用未筛选的 BP 神经网络模型中, 深度 20 ~ 40 cm 下模型拟合效果最优, 建模集和验证集 R^2_{adj} 均高于 0.53, 同时其 RMSE 也相对最大, 分别为 0.024%、0.026%, 反演误差较大; 深度 40 ~ 60 cm 模型拟合效果最差, 建模集验证集 R^2_{adj} 均低于其他深度, 分别为 0.493、0.429, 反演误差也较大; 深度 0 ~ 20 cm 和 0 ~ 40 cm 模型效果相近, 0 ~ 40 cm 建模集 R^2_{adj} 略高于 0 ~ 20 cm, 但其验证集 RMSE 大于 0 ~ 20 cm, 反演误差略大; 深度 0 ~ 60 cm 存在一定过拟合现象, 验证集 R^2_{adj} 较建模集低 0.11。

采用全子集筛选后的多元线性回归模型中, 深度 0 ~ 40 cm 和 0 ~ 60 cm 下模型效果较优, 建模集和验证集 R^2_{adj} 均高于 0.51, 具有较好的拟合效果和泛化性能, 0 ~ 40 cm 略优于 0 ~ 60 cm, 主要表现在

反演误差上, 建模集和验证集 RMSE 相对低于后者 10%、25%; 深度 40 ~ 60 cm 下模型拟合效果相对最差, 建模集和验证集 R^2_{adj} 均明显低于其余 4 个深度, 分别为 0.453、0.431, 建模集和验证集 RMSE 相对较大, 反演误差偏大; 深度 20 ~ 40 cm 下模型拟合效果优于 0 ~ 20 cm, 其建模集和验证集 R^2_{adj} 分别略高 0.008、0.030, 但深度 0 ~ 20 cm 反演误差控制较好, RMSE 相对减小约 16%、37%。

总体来说, 在 BP 神经网络模型中, 除深度 20 ~ 40 cm 外, 其余各深度筛选后模型拟合效果和泛化性能优于筛选前, 且筛选后模型稳定性更强。全子集 BP 神经网络模型在不同深度土壤含水率的反演效果由好到差依次为: 0 ~ 40 cm、0 ~ 60 cm、20 ~ 40 cm、0 ~ 20 cm、40 ~ 60 cm。

2.3.3 支持向量机模型建立与验证

分别以不同深度下筛选前后的波段反射率及光谱指数为自变量, 土壤含水率为因变量, 运用支持向量机模型进行不同深度下土壤含水率估算。其建模集和验证集精度如表 6 所示。

表 6 基于支持向量机全子集筛选前后的土壤含水率反演模型

Tab.6 Inversion model of soil moisture content before and after screening of all subsets based on SVM

深度/cm	未筛选				筛选后			
	建模集		验证集		建模集		验证集	
	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %	R^2_{adj}	RMSE/ %
0 ~ 20	0.489	0.021	0.526	0.016	0.514	0.021	0.518	0.016
20 ~ 40	0.528	0.025	0.502	0.027	0.501	0.025	0.525	0.027
40 ~ 60	0.521	0.019	0.383	0.026	0.506	0.020	0.407	0.025
0 ~ 40	0.563	0.020	0.423	0.020	0.544	0.020	0.471	0.021
0 ~ 60	0.565	0.022	0.549	0.027	0.534	0.023	0.509	0.026

从表 6 可以看出, 采用未筛选的支持向量机模型中, 深度 0 ~ 60 cm 下模型拟合效果最优, 建模集和验证集 R^2_{adj} 分别为 0.565、0.549, 均高于其余深度, RMSE 均大于 0.022%, 反演误差略大; 深度 20 ~ 40 cm 模型拟合效果仅次于 0 ~ 60 cm, 建模集和验证集 R^2_{adj} 均高于 0.50, 建模集和验证集 RMSE 分别为 0.025%、0.027%, 反演误差相对最大; 深度 0 ~ 20 cm 模型拟合效果接近 20 ~ 40 cm, 其建模集和验证集 RMSE 低于后者 0.004、0.011 个百分点, 反演误差控制较好; 深度 0 ~ 40 cm 和 40 ~ 60 cm 下模型有过拟合现象, 验证集 R^2_{adj} 都低于建模集 0.14 左右, 其中 40 ~ 60 cm 建模集和验证集 R^2_{adj} 都低于 0 ~ 40 cm, 模型拟合效果相对最差, 验证集 RMSE 达到 0.026%, 反演误差较大。

采用全子集筛选的支持向量机模型中,深度0~60 cm下模型效果相对较优,建模集验证集 R^2_{adj} 分别为0.534、0.509,模型拟合效果和泛化性能较好, RMSE在0.023%~0.026%,反演误差中等;深度0~20 cm和20~40 cm模型效果接近,建模集和验证集 R^2_{adj} 均高于0.5,0~20 cm反演误差控制较好,其RMSE低于深度20~40 cm 16%以上;深度0~40 cm和40~60 cm下模型有轻微过拟合现象,验证集 R^2_{adj} 分别低于建模集0.07~0.1,其中40~60 cm建模集和验证集 R^2_{adj} 低于0~40 cm,模型拟合效果最差,验证集RMSE达到0.025%,反演误差较大。

总体来说,在支持向量机模型中,深度0~60 cm筛选后模型拟合效果略有下降,其余各深度筛选后模型拟合效果和泛化性能优于筛选前,过拟合现象得到一定改善,反演误差相当。全子集支持向量机模型在不同深度土壤含水率的反演效果由好到差依次为:0~60 cm、0~40 cm、0~20 cm、20~40 cm、40~60 cm。

2.4 反演效果综合评价

通过对比表4~6的数据及分析可知,多元线性回归模型中,筛选后各深度模型的建模集和验证集 R^2_{adj} 均有一定提高且模型稳定性较强,模型拟合效果和泛化能力提升, RMSE未发生显著变化,反演误差

相近;BP神经网络模型中,筛选后除深度20~40 cm模型的建模集和验证集 R^2_{adj} 减小约0.04外,其余深度模型的建模集和验证集 R^2_{adj} 差值明显减小, RMSE保持不变,模型保持拟合效果和反演误差的同时泛化性能提升,减轻了过拟合现象;支持向量机模型中,筛选后除深度0~60 cm模型的建模集和验证集 R^2_{adj} 减小0.03~0.04,其余深度模型的建模集和验证集 R^2_{adj} 差值减小,最大不到0.1, RMSE基本保持不变,筛选后模型拟合效果和反演误差未有显著变化,过拟合现象得到改善。综上所述,全子集筛选的最优自变量组合对土壤含水率有较高的敏感性,筛选结果比较可靠。

以建模集和验证集的 R^2_{adj} 、RMSE为评价指标,综合对比全子集筛选后3个模型在5个深度0~20 cm、20~40 cm、40~60 cm、0~40 cm和0~60 cm下的反演效果,得到土壤含水率反演深度和反演模型综合对比如图3、4所示。一方面进行反演深度评价,通过分析线性回归和2种机器学习模型在不同深度下的反演效果,评价植被覆盖条件下GF-1卫星对不同深度的土壤含水率的敏感性,得到最佳反演深度。另一方面进行反演模型评价,通过对比相同深度下线性回归和机器学习模型的反演效果,评价植被覆盖条件下各模型对土壤含水率的反演能力,得到最佳反演模型。




图3 土壤含水率反演深度综合对比图

Fig. 3 Comprehensive contrast diagrams of soil moisture content inversion depth

2.4.1 反演深度评价

各模型在不同深度下的反演效果已在2.3节中进行了详细讨论,从图3可以看出,在深度0~40 cm和0~60 cm下,建模集和验证集 R^2_{adj} 总体上高于其他深度,各模型均能在该2种深度下达到较好的拟合效果。在深度0~40 cm下,建模集和验证集的RMSE明显低于0~60 cm,各模型在该深度下能够较好的控制反演误差。因此综合以上2个指标,0~

40 cm是植被覆盖条件下GF-1卫星反演土壤含水率的最佳深度。深度40~60 cm R^2_{adj} 明显最低,拟合效果较差的同时存在中等反演误差;深度0~20 cm模型反演误差相对于其他深度较低,但模型拟合效果整体不及20~40 cm。因此,GF-1卫星对深度40~60 cm土壤含水率反演效果最差,对深度0~40 cm和0~60 cm反演效果均较好,其中深度0~40 cm相对更佳。




图4 土壤含水率反演模型综合对比

Fig.4 Comprehensive contrast diagrams of soil moisture content inversion model

综合 R^2_{adj} 、RMSE 2 个指标,得到植被覆盖条件下 GF-1 卫星在不同深度土壤含水率的敏感程度由强到弱依次为:0 ~ 40 cm、0 ~ 60 cm、20 ~ 40 cm、0 ~ 20 cm、40 ~ 60 cm。

2.4.2 反演模型评价

从图4可以看出,BP神经网络模型在各深度下的 R^2_{adj} 总体上高于其他模型,虽然深度0 ~ 20 cm、20 ~ 40 cm下建模集和验证集 R^2_{adj} 略低于同等深度下的支持向量机模型,但其总体的拟合效果和泛化能力仍较好,该模型深度下RMSE与其他深度接近,反演误差基本相同,因此BP神经网络模型是反演水分的最佳模型。支持向量机模型在深度40 ~ 60 cm、0 ~ 40 cm下建模集和验证集 R^2_{adj} 的差值较大,模型稳定性较差,因此支持向量机模型反演水分效果相对略差;多元线性回归模型各深度下的 R^2_{adj} 总体上低于其他模型,0 ~ 20 cm、20 ~ 40 cm、40 ~ 60 cm拟合效果相对较差,因此多元线性回归模型反演效果略差。

综合 R^2_{adj} 、RMSE 2 个指标,得到植被覆盖条件下3种模型对土壤含水率的反演能力由强到弱依次为:BP神经网络模型、支持向量机模型、多元线性回归模型。

3 讨论

利用GF-1卫星4个波段和15个光谱指数,经过全子集筛选的方法确定不同土壤深度条件下敏感变量组合方式,个别模型和深度筛选后模型效果略有下降,其余模型的拟合效果和泛化能力均有提高,反演误差基本保持不变,过拟合现象有所减轻。3种模型模拟结果表明,筛选后的敏感变量组合方

式仅用2~4个自变量即可得到筛选前同等精度的反演效果,且模型稳定性较大提高。罗湘华等^[53]使用全子集有效地消除了共线性在土地利用变化统计分析中的影响,李长春等^[44]在评估叶片表面指数时,也发现使用全子集筛选方法创建的回归模型与传统线性回归和机器学习模型相比更加贴合实际,符合全子集筛选有效的结论。

对比全子集筛选后的3种模型在不同深度下的反演结果,发现在植被覆盖条件下利用GF-1号卫星数据反演深度0 ~ 40 cm的土壤含水率效果最佳,深度0 ~ 60 cm次之。深层土壤(40 ~ 60 cm)反演效果较差,可能是由于深层含水率的空间变异性相对更小,不同样本点之间的光谱差异更多由浅层土壤造成,一定程度上掩盖了深层(40 ~ 60 cm)土壤含水率的光谱差异,并且深层(40 ~ 60 cm)土壤平均含水率更高,对植被的胁迫性也相对较小,所反映出来的差异也更小。张智韬等^[54]利用TM5、TM7数据,应用归一化土壤湿度指数监测土壤含水率也得出反演效果最好的土层深度为0 ~ 40 cm的结论,屈创^[55]基于多源遥感数据的白龙江流域水分反演研究里也表明回归模型对深度0 ~ 40 cm范围的土壤水分反演精度最高。其主要原因是:①表层土壤水分容易受到太阳辐射、降水、风速等多种因素的影响,并且卫星成像时间和野外实测土壤含水率数据很难达到完全同步,下层土壤处于一个被保护的状态,受到外界环境的影响较小,其土壤水分的变化在一段时间内能维持在一个相对稳定的状态。②作物耗水主要集中在0 ~ 40 cm的土层^[56],作物生长期根系对土壤水分反应敏感,受到土壤水分胁迫更加明显。在本次研究的河套灌区中,7月下旬的主要

作物葵花处于苗期后期,生理需水量处于中等水平,主要吸水层集中在距地表 0 ~ 50 cm 土层之间^[57],最大吸水峰值在 30 cm 土层之间,与本文研究结果基本相符。

本研究表明利用 GF-1 卫星反演植被覆盖条件下农田土壤含水率具有可行性,评价了植被覆盖条件下 GF-1 卫星对不同深度土壤含水率的反演能力,研究不同深度下最优的土壤含水率反演模型,为全灌区干旱监测与预警提供了一定技术依据。CHEN 等^[58]率先对 GF-1 宽视场(WFV)传感器土壤水分反演观测能力做出了定量评价,NIE 等^[59]在进行光谱指数在土壤水分反演中的适宜性评价时也得出使用 GF-1 影像获得的整体反演结果优于使用 Landsat8 OLI 影像的结论;GF-1 光学数据与 SAR 数据结合能有效提高土壤水分的反演精度,WANG 等^[60]基于 GF-1 卫星计算的植被指数与 Sentinel-1 SAR 数据,结合水云模型(WMC)和高级积分方程模型(AIEM)反演土壤水分的 R^2 为 0.52 ~ 0.56, RMSE 为 0.052% ~ 0.064%;TAO 等^[61]使用多时相 SAR 数据和 GF-1 数据提出了改进的植被反向散射模型,结果表明该模型对于土壤水分估算准确。本文通过全子集筛选法确定了不同土壤深度的最优光谱指数组合,得到了与以上研究同等精度的土壤水分反演结果。

解放闸灌域盐渍化问题突出,地下水位偏高,会对土壤水分反演造成一定程度上的影响^[62],本文中采用的 7 个土壤指数(包括 6 个盐分指数)在以往多用于土壤含盐量的研究,首次将其利用在植被覆盖条件下土壤含水率的反演,结果表明这些盐分指数在各个深度下的土壤含水率反演模型中都表现良好,为未来在盐渍化地区的土壤含水率反演中提供

了新的思路,未来可以进一步研究分析水盐之间的相互作用。此外,采用更高空间分辨率卫星遥感数据,考虑不同地区农田的种植结构差异,以及不同作物不同生育期根系影响土壤水分特点,本文结论是否具有更广泛的适用性还有待进一步研究。

4 结 论

(1)利用全子集筛选法确定了不同土壤深度下光谱指数的最优自变量组合,通过对比筛选前后各模型的反演效果,一定程度上证明了利用 GF-1 卫星反演植被覆盖条件下农田土壤含水率的可行性,结果表明筛选后模型反演效果有所提升,能减轻过拟合现象,全子集筛选有效。

(2)0 ~ 40 cm 是本次植被覆盖条件下 GF-1 卫星反演农田土壤含水率的最佳深度,各模型建模集和验证集 R_{adj}^2 总体能达到 0.50 以上, RMSE 均在 0.02% 左右,该深度下模型总体拟合效果好,反演误差控制适当。40 ~ 60 cm 相对最差,但各模型建模集和验证集 R_{adj}^2 也能达到 0.40。综合对比得到植被覆盖条件下 GF-1 卫星对各深度土壤含水率的敏感程度由强到弱依次为:0 ~ 40 cm、0 ~ 60 cm、20 ~ 40 cm、0 ~ 20 cm、40 ~ 60 cm。

(3)筛选后 BP 神经网络模型是植被覆盖条件下反演农田土壤水分的最佳模型,各深度建模集和验证集 R_{adj}^2 均在 0.43 以上,模型拟合效果较好,反演误差与其余两种模型相当,特别在深度 0 ~ 40 cm 表现良好,建模集和验证集 R_{adj}^2 能达到 0.559、0.514,反演误差控制在 0.02% 左右。综合对比得到植被覆盖条件下 3 种模型对土壤含水率的反演能力由强到弱依次为:BP 神经网络模型、支持向量机模型、多元线性回归模型。

参 考 文 献

- [1] 蔡庆空,陶亮亮,蒋瑞波,等. 基于理论干湿边与改进 TVDI 的麦田土壤水分估算研究[J]. 农业机械学报,2020,51(7): 202-209.
CAI Qingkong,TAO Liangliang,JIANG Ruibo,et al. Soil moisture estimation of wheat field based on theoretical dry-wet edge and improved TVDI[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(7):202-209. (in Chinese)
- [2] 杨涛,宫辉力,李小娟,等. 土壤水分遥感监测研究进展[J]. 生态学报,2010,30(22): 6264-6277.
YANG Tao,GONG Huili,LI Xiaojuan,et al. Progress of soil moisture monitoring by remote sensing[J]. Acta Ecologica Sinica,2010,30(22):6264-6277. (in Chinese)
- [3] 蒙继华,吴炳方,杜鑫,等. 遥感在精准农业中的应用进展及展望[J]. 国土资源遥感,2011(3): 1-7.
MENG Jihua,WU Bingfang, DU Xin,et al. A review and outlook of applying remote sensing to precision agriculture[J]. Remote Sensing for Land & Resources,2011(3):1-7. (in Chinese)
- [4] 郑小坡,孙越君,秦其明,等. 基于可见光-短波红外波谱反射率的裸土土壤含水量反演建模[J]. 光谱学与光谱分析,2015,35(8): 2113-2118.
ZHENG Xiaopo,SUN Yuejun,QIN Qiming,et al. Bare soil moisture inversion model based on visible-shortwave infrared reflectance[J]. Spectroscopy and Spectral Analysis,2015,35(8): 2113-2118. (in Chinese)
- [5] 范文义,李明泽,应天玉. 荒漠化地区土壤含水量的遥感定量反演[J]. 应用生态学报,2008,19(5): 1046-1051.
FAN Wenyi,LI Mingze,YING Tianyu. A remote sensing quantitative retrieval of soil water content in desertification region[J]. Chinese Journal of Applied Ecology,2008,19(5):1046-1051. (in Chinese)
- [6] LIU Z,XIA Z,CHEN F,et al. Soil moisture index model for retrieving soil moisture in semiarid regions of China[J]. IEEE

- Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2020,13: 5929 – 5937.
- [7] LAMBIN E F,EHRLICH D. The surface temperature-vegetation index space for land cover and land-cover change analysis[J]. International Journal of Remote Sensing,2007,17(3): 463 – 487.
- [8] HUETE A. A soil-adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment,1988,25(3): 295 – 309.
- [9] 周磊,武建军,张洁. 以遥感为基础的干旱监测方法研究进展[J]. 地理科学,2015,35(5):630 – 636.
ZHOU Lei,WU Jianjun,ZHANG Jie. Remote sensing-based drought monitoring approach and research progress[J]. Scientia Geographica Sinica,2015,35(5):630 – 636. (in Chinese)
- [10] MAJOR D J,BARET F,GUYOT G. A ratio vegetation index adjusted for soil brightness[J]. International Journal of Remote Sensing,1990,11(5): 727 – 740.
- [11] BARET F,GUYOT G. Potentials and limits of vegetation indices for LAI and APAR assessment[J]. Remote Sensing of Environment,1991,35(2): 161 – 173.
- [12] 夏权,夏萍,陈黎卿,等. 基于多光谱遥感的土壤含水量定量监测与分析[J]. 安徽农业大学学报,2015,42(3): 439 – 443.
XIA Quan,XIA Ping,CHEN Liqing,et al. Quantitative analysis of the soil moisture content based on multispectral remote sensing data[J]. Journal of Anhui Agricultural University, 2015, 42(3): 439 – 443. (in Chinese)
- [13] 吴春雷,秦其明,李梅,等. 基于光谱特征空间的农田植被区土壤湿度遥感监测[J]. 农业工程学报,2014,30(16):106 – 112.
WU Chunlei,QIN Qiming,LI Mei,et al. Soil moisture monitoring of vegetative area in farmland by remote sensing based on spectral feature space[J]. Transactions of the CSAE,2014,30(16):106 – 112. (in Chinese)
- [14] 蔡亮红,丁建丽. 基于改进植被指数土壤水分遥感反演[J]. 干旱区地理,2017,40(6):1248 – 1255.
CAI Lianghong,DING Jianli. Remote sensing inversion of soil moisture based on modified vegetation index[J]. Arid Land Geography,2017,40(6):1248 – 1255. (in Chinese)
- [15] WEST H,QUINN N,HORSWELL M,et al. Assessing vegetation response to soil moisture fluctuation under extreme drought using Sentinel-2[J]. Water (Basel),2018,10(7): 838.
- [16] NATALIE R W, LAURA M N. Analysis of vegetation recovery surrounding a restored wetland using the normalized difference infrared index(NDII) and normalized difference vegetation index(NDVI)[J]. International Journal of Remote Sensing,2018,39(10):3243 – 3274.
- [17] REZA D B,HAMIDREZA K,ALI K,et al. Measurement and zonation of soil surface moisture in arid and semi-arid regions using Landsat8 images[J]. Arabian Journal of Geosciences,2020,13:826.
- [18] GAO Y G, LI Q. A segmented particle swarm optimization convolutional neural network for land cover and land use classification of remote sensing images[J]. Remote Sensing Letter,2019,10(12):1182 – 1191.
- [19] LIU B,LI Y,ZHANG Q,et al. The application of GF-1 imagery to detect ships on the Yangtze river[J]. Journal of the Indian Society of Remote Sensing,2017,45(1): 179 – 183.
- [20] 贺佳,郭燕,张彦,等. 基于 GF-1 数据的夏玉米 FPAR 遥感动态估算[J]. 农业机械学报,2022,53(4):164 – 172,321.
HE Jia,GUO Yan,ZHANG Yan,et al. Dynamic estimation FPAR of summer maize based on GF-1 satellite data[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(4):164 – 172,321. (in Chinese)
- [21] 薛兴盛,郑硕,白杨,等. 徐州市 GF-1 卫星气溶胶光学厚度反演与空间特征分析[J]. 安徽农业大学学报,2019,46(4): 689 – 696.
XUE Xingsheng,ZHENG Shuo,BAI Yang,et al. Aerosol optical depth retrieval and spatial characteristics analysis of GF-1 satellite in Xuzhou[J]. Journal of Anhui Agricultural University, 2019,46(4):689 – 696. (in Chinese)
- [22] 彦立利,高健峰,王建,等. 基于 GF-1 卫星遥感的冰川边界识别[J]. 冰川冻土, 2020, 42(4): 1400 – 1406.
YAN Lili,GAO Jianfeng,WANG Jian,et al. Glacier mapping based on GF-1 satellite remote sensing[J]. Journal of Glaciology and Geocryology, 2020,42(4):1400 – 1406. (in Chinese)
- [23] YU R,LIU T,XU Y,et al. Analysis of salinization dynamics by remote sensing in Hetao Irrigation District of North China[J]. Agricultural Water Management,2010,97(12): 1952 – 1960.
- [24] 张娜,张栋良,屈忠义,等. 内蒙古河套灌区区域土壤质地空间变异分析——以解放闸灌域为例[J]. 干旱区资源与环境,2015,29(12): 155 – 163.
ZHANG Na,ZHANG Dongliang,QU Zhongyi,et al. The spatial variation of soil texture in Hetao Irrigation District in Inner Mongolia[J]. Journal of Arid Land Resources and Environment, 2015,29(12):155 – 163. (in Chinese)
- [25] 郑倩,史海滨,李仙岳,等. 河套灌区解放闸灌域植被指数与地下水埋深的定量关系[J]. 水土保持学报,2021,35(1): 301 – 306,313.
ZHENG Qian,SHI Haibin,LI Xianyue,et al. Study on the quantitative relationship between vegetation index and groundwater depth in Jiefangzha Irrigation Area in the Hetao Irrigation District[J]. Journal of Soil and Water Conservation,2021,35(1): 301 – 306,313. (in Chinese)
- [26] 乔冬梅. 盐渍化地区 SPAC 系统能态分析及根系吸水模型研究[D]. 呼和浩特:内蒙古农业大学,2005.
QIAO Dongmei. Study on the energy of SPAC system and root uptake model in saline soil[D]. Hohhot:Inner Mongolia Agricultural University,2005. (in Chinese)
- [27] 胡琦. 河套灌区膜下滴灌农田水盐运移和玉米生长对农膜残留的响应机制研究[D]. 呼和浩特:内蒙古农业大学,2020.
HU Qi. Response of soil water and salt transport and corn growth to plastic-film residue under dripped plastic-film mulching in Hetao Irrigation District[D]. Hohhot:Inner Mongolia Agricultural University,2020. (in Chinese)
- [28] ZHANG J,ZHANG Z,CHEN J,et al. Estimating soil salinity with different fractional vegetation cover using remote sensing[J]. Land Degradation & Development, 2021, 32(2): 597 – 612.
- [29] 张川,陈洪松,聂云鹏,等. 喀斯特地区洼地剖面土壤含水率的动态变化规律[J]. 中国生态农业学报,2013,21(10):

1225 – 1232.

ZHANG Chuan, CHEN Hongsong, NIE Yunpeng, et al. Dynamics of soil profile water content in peak-cluster depression areas in karst region[J]. Chinese Journal of Eco-Agriculture, 2013, 21(10): 1225 – 1232. (in Chinese)

[30] 徐露, 张丹, 向宇国, 等. 金沙江下游季节性干旱区紫色土坡耕地土壤水分变化特征[J]. 土壤通报, 2021, 52(3): 585 – 593.

XU Lu, ZHANG Dan, XIANG Yuguo, et al. Moisture characteristics of purple soil in a seasonal arid area in the lower reaches of the Jinsha River[J]. Chinese Journal of Soil Science, 2021, 52(3): 585 – 593. (in Chinese)

[31] 徐志尧, 张钦弟, 杨磊. 半干旱黄土丘陵区土壤水分生长季动态分析[J]. 干旱区资源与环境, 2018, 32(3): 146 – 151.

XU Zhiyao, ZHANG Qindi, YANG Lei. Analysis of temporal variation of soil water in a growing season in semiarid loess hilly area[J]. Journal of Arid Land Resources and Environment, 2018, 32(3): 146 – 151. (in Chinese)

[32] DOUAOU A E K, NICOLAS H, WALTER C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2006, 134(1 – 2): 217 – 230.

[33] ALLBED A, KUMAR L, ALDAKHEEL Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: applications in a date palm dominated region[J]. Geoderma, 2014, 230 – 231: 1 – 8.

[34] LIU H Q, HUETE A R. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise[J]. IEEE Transactions on Geoscience & Remote Sensing, 1995, 33(2): 457 – 465.

[35] YAO Z Y, LIU J J, ZHAO X W, et al. Spatial dynamics of aboveground carbon stock in urban green space: a case study of Xi'an, China[J]. Journal of Arid Land, 2015, 7(3): 350 – 360.

[36] RICHARDSON A J, WIEGAND L C. Distinguishing vegetation from soil background information[J]. Photogrammetric Engineering and Remote Sensing, 1977, 43(12): 1541 – 1552.

[37] GHULAM A, QIN Q, ZHAN Z. Designing of the perpendicular drought index[J]. Environmental Geology, 2007, 52(6): 1045 – 1052.

[38] RUNING S W, JUSTICE O, SALOMONSON V, et al. Terrestrial remote sensing science and algorithms planned for EOS/MODIS[J]. International Journal of Remote Sensing, 1994, 15(17): 3587 – 3620.

[39] 张智韬, 杜瑞麒, 杨帅, 等. 水盐交互作用对河套灌区土壤光谱特征的影响[J]. 农业工程学报, 2020, 36(18): 153 – 164.

ZHANG Zhitao, DU Ruiqi, YANG Shuai, et al. Effects of water-salt interaction on soil spectral characteristics in Hetao Irrigation Areas of Inner Mongolia, China[J]. Transactions of the CSAE, 2020, 36(18): 153 – 164. (in Chinese)

[40] SHOBA P, RAMAKRISHNAN S S. Multispectral and microwave remote sensing models to survey soil moisture and salinity[J]. Land Degradation & Development, 2017, 28(4): 1412 – 1425.

[41] 张智韬, 韩佳, 陈皓锐, 等. 基于全子集-分位数回归的土壤含盐量反演研究[J]. 农业机械学报, 2019, 50(10): 142 – 152.

ZHANG Zhitao, HAN Jia, CHEN Haorui, et al. Soil salinity inversion method by satellite remote sensing based on best subsets-quantile regression model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(10): 142 – 152. (in Chinese)

[42] HOCKING R R, LESLIE R N. Selection of the best subset in regression analysis[J]. Technometrics, 1967, 9: 4, 531 – 540.

[43] 谭丞轩, 张智韬, 许崇豪, 等. 无人机多光谱遥感反演各生育期玉米根域土壤含水率[J]. 农业工程学报, 2020, 36(10): 63 – 74.

TAN Chengxuan, ZHANG Zhitao, XU Chonghao, et al. Soil water content inversion model in field maize root zone based on UAV multispectral remote sensing[J]. Transactions of the CSAE, 2020, 36(10): 63 – 74. (in Chinese)

[44] 李长春, 牛庆林, 杨贵军, 等. 基于无人机数码影像的大豆育种材料叶面积指数估测[J]. 农业机械学报, 2017, 48(8): 147 – 158.

LI Changchun, NIU Qinglin, YANG Guijun, et al. Estimation of leaf area index of soybean breeding materials based on UAV digital images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8): 147 – 158. (in Chinese)

[45] CHEN Y, QIU Y, ZHANG Z, et al. Estimating salt content of vegetated soil at different depths with Sentinel-2 data[J/OL]. PeerJ 8:e10585. <http://doi.org/10.7717/peerj.1058>.

[46] 陈鹏, 冯海宽, 李长春, 等. 无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J]. 农业工程学报, 2019, 35(11): 63 – 74.

CHEN Peng, FENG Haikuan, LI Changchun, et al. Estimation of chlorophyll content in potato using fusion of texture and spectral features derived from UAV multispectral image[J]. Transactions of the CSAE, 2019, 35(11): 63 – 74. (in Chinese)

[47] ATKINSON P M, JEGANATHAN C, DASH J, et al. Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology[J]. Remote Sensing of Environment, 2012, 123: 400 – 417.

[48] 闫闯. 多元回归模型中变量选择问题研究[D]. 哈尔滨: 黑龙江大学, 2011.

YAN Chuang. Research on variable selection in multiple regression model[D]. Harbin: Heilongjiang University, 2011. (in Chinese)

[49] 闫妍宇, 李超, 欧光龙, 等. 基于地理加权回归模型的思茅松生物量遥感估测[J]. 林业资源管理, 2017(1): 82 – 90.

LÜ Yanyu, LI Chao, OU Guanglong, et al. Remote sensing estimation of biomass of *pinus kesiya* var. *langbianensis* by geographically weighted regression models[J]. Forest Resources Management, 2017(1): 82 – 90. (in Chinese)

[50] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995(20): 273 – 297.

[51] 田明璐. 西北地区冬小麦生长状况高光谱遥感监测研究[D]. 杨凌: 西北农林科技大学, 2017.

TIAN Minglu. Monitoring winter wheat growth conditions in the northwest region of China by using hyperspectral remote sensing[D]. Yangling: Northwest A&F University, 2017. (in Chinese)

[52] 李晓宇, 张新峰, 沈兰荪. 支持向量机(SVM)的研究进展[J]. 测控技术, 2006(5): 7 – 12.

LI Xiaoyu, ZHANG Xinfeng, SHEN Lansun. Some development on support vector machine[J]. Measurement & Control Technology, 2006(5): 7 – 12. (in Chinese)

[53] 罗湘华, 倪晋仁, 罗华铭. 论土地利用变化统计分析中的多重共线性问题[J]. 应用基础与工程科学学报, 2001, 9(4):

297 – 306.

LUO Xianghua, NI Jinren, LUO Huaming. Multicollinearity problems and their treatment in statistical studies of land use change [J]. Journal of Basic Science and Engineering, 2001, 9(4) : 297 – 306. (in Chinese)

[54] 张智韬,李援农,杨江涛,等. 遥感监测土壤含水率模型及精度分析[J]. 农业工程学报, 2008, 24(8) : 152 – 156.

ZHANG Zhitao, LI Yuannong, YANG Jiangtao, et al. Model for monitoring soil moisture using remote sensing and its accuracy analysis[J]. Transactions of the CSAE, 2008, 24(8) : 152 – 156. (in Chinese)

[55] 屈创. 基于多源遥感数据的白龙江流域土壤水分反演研究[D]. 兰州: 兰州大学, 2014.

QU Chuang. The study of soil moisture retrieval based on multi-source RS data in the Bailong Basin[D]. Lanzhou: Lanzhou University, 2014. (in Chinese)

[56] 陈亮,姚保顺,何厚军,等. 基于 HJ-1B 数据的作物根系土壤水分遥感监测[J]. 华北水利水电大学学报(自然科学版), 2016, 37(3) : 27 – 31.

CHEN Liang, YAO Baoshun, HE Houjun, et al. Monitoring soil moisture in root-system zone based on HJ-1B data with remote sensing technology[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2016, 37(3) : 27 – 31. (in Chinese)

[57] 乔冬梅,史海滨,薛铸. 盐渍化地区油料向日葵根系吸水模型的建立[J]. 农业工程学报, 2006, 22(8) : 44 – 49.

QIAO Dongmei, SHI Haibin, XUE Zhu. Development of root-water-uptake model for oil sunflower in saline soil [J]. Transactions of the CSAE, 2006, 22(8) : 44 – 49. (in Chinese)

[58] CHEN N C, LI J Z, ZHANG X. Quantitative evaluation of observation capability of GF-1 wide field of view sensors for soil moisture inversion[J]. Journal of Applied Remote Sensing, 2015, 9(1) : 097097.

[59] NIE Y, TAN Y, DENG Y, et al. Suitability evaluation of typical drought index in soil moisture retrieval and monitoring based on optical images[J]. Remote Sensing, 2020, 12(16) : 2587.

[60] WANG Q, LI J, JIN T, et al. Comparative analysis of Landsat-8, Sentinel-2, and GF-1 data for retrieving soil moisture over wheat farmlands[J]. Remote Sensing, 2020, 12(17) : 2708.

[61] TAO L, WANG G, CHEN W, et al. Soil moisture retrieval from SAR and optical data using a combined model[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(2) : 637 – 647.

[62] 贾艳茹,布和. 基于遥感农田表层土壤水分反演研究[J]. 内蒙古水利, 2015(3) : 9 – 10.

JIA Yanru, BU He. Research on retrieval of surface soil moisture in farmland based on remote sensing[J]. Inner Mongolia Water Resources, 2015(3) : 9 – 10. (in Chinese)

(上接第 238 页)

[32] DIAO S, LIU C, ZHANG T, et al. Extraction of remote sensing information for lake salinity level based on SVM: a case from Badain Jaran desert in Inner Mongolia[J]. Remote Sensing for Land & Resources, 2016, 28(4) : 114 – 118.

[33] 梁栋,管青松,黄文江,等. 基于支持向量机回归的冬小麦叶面积指数遥感反演[J]. 农业工程学报, 2013, 29(7) : 117 – 123.

LIANG Dong, GUAN Qingsong, HUANG Wenjiang, et al. Remote sensing inversion of leaf area index based on support vector machine regression in winter wheat[J]. Transactions of the CSAE, 2013, 29(7) : 117 – 123. (in Chinese)

[34] YAO R J, YANG J S, ZOU P, et al. BP neural network model for spatial distribution of regional soil water and salinity[J]. Acta Pedologica Sinica, 2009, 46(5) : 788 – 794.

[35] 郝大磊,肖青,闻建光,等. 定量遥感升尺度转换方法研究进展[J]. 遥感学报, 2018, 22(3) : 408 – 423.

HAO Dalei, XIAO Qing, WEN Jianguang, et al. Advances in upscaling methods of quantitative remote sensing[J]. Journal of Remote Sensing, 2018, 22(3) : 408 – 423. (in Chinese)

[36] WANG J, DING J, YU D, et al. Machine learning-based detection of soil salinity in an arid desert region, Northwest China: a comparison between Landsat-8 OLI and Sentinel-2 MSI[J]. Science of the Total Environment, 2020, 707 : 136092.

[37] 冯娟. 土壤盐渍化遥感建模尺度效应分析[D]. 乌鲁木齐: 新疆大学, 2018.

FENG Juan. Scale effect analysis of soil salinization modeling based on remote sensing[D]. Urumqi: Xinjiang University, 2018. (in Chinese)

[38] 张智韬,魏广飞,姚志华,等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. 农业机械学报, 2019, 50(12) : 151 – 160.

ZHANG Zhitao, WEI Guangfei, YAO Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12) : 151 – 160. (in Chinese)

[39] 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)

[40] 奚雪,赵庚星,高鹏,等. 基于 Sentinel 卫星及无人机多光谱的滨海冬小麦种植区土壤盐分反演研究——以黄三角垦利区为例[J]. 中国农业科学, 2020, 53(24) : 5005 – 5016.

XI Xue, ZHAO Gengxing, GAO Peng, et al. Inversion of soil salinity in coastal winter wheat growing area based on sentinel satellite and unmanned aerial vehicle multi-spectrum—a case study in Kenli District of the Yellow River Delta[J]. Scientia Agricultura Sinica, 2020, 53(24) : 5005 – 5016. (in Chinese)

[41] ZHANG S, ZHAO G. A harmonious satellite-unmanned aerial vehicle-ground measurement inversion method for monitoring salinity in coastal saline soil[J]. Remote Sensing, 2019, 11(14) : 1700.