doi:10.6041/j.issn.1000-1298.2023.06.032

基于无人机-卫星遥感升尺度的土壤水分监测模型研究

马　仪[1]　黄组桂[2,3]　贾江栋[2,3]　罗林育[2,3]　王　爽[2,3]　姚一飞[2,3]

(1.云南电网有限责任公司电力科学研究院,昆明 650217;
2.西北农林科技大学水利与建筑工程学院,陕西杨凌 712100;
3.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:土壤水分是研究土壤-植物-大气循环系统中能量与物质交换的关键,通过尺度转换方法将无人机遥感数据上推以修正卫星数据,可有效改善卫星遥感反演模型精度。本文以河套灌区为研究对象,分别采用重采样和 TsHARP 升尺度法,引入多元线性回归(MLR)、BP 神经网络(BPNN)和支持向量机(SVM)算法构建不同土壤深度下无人机-卫星升尺度土壤含水率反演模型。研究结果表明:重采样升尺度法在不同土壤深度下模型整体精度由高到低依次为 SVM、MLR、BPNN,其中在土壤深度 0~60 cm 下采用 SVM 模型最优,R^2 达到 0.571,RMSE 为 0.022%;TsHARP 升尺度法在不同土壤深度下模型整体精度由高到低依次为 BPNN、SVM、MLR,其中在土壤深度 0~60 cm下采用 BPNN 模型最优,R^2达到 0.829,RMSE 为 0.015%。与升尺度修正前对应土壤深度模型对比,两种升尺度方法均能明显提高卫星遥感对土壤含水率的反演精度,但 TsHARP 升尺度法整体优于重采样法;重采样法的 R^2由 0.413 提升至 0.571,RMSE 由 0.026% 降至 0.022%(降幅 15.4%);TsHARP 升尺度法的 R^2由 0.428 提升至 0.829,RMSE 由 0.025% 降至 0.015%(降幅 40.0%)。本研究可为大尺度范围灌区土壤水分高精度监测提供理论和技术支撑。

关键词:土壤水分;升尺度;高分一号卫星;无人机;监测模型

中图分类号:S252;TP79　　**文献标识码**:A　　**文章编号**:1000-1298(2023)06-0307-12　　**OSID**:

Soil Moisture Monitoring Model Based on UAV - Satellite Remote Sensing Scale-up

MA Yi[1]　HUANG Zugui[2,3]　JIA Jiangdong[2,3]　LUO Linyu[2,3]　WANG Shuang[2,3]　YAO Yifei[2,3]

(1. *Electric Power Science Research Institute, Yunnan Power Grid Co., Ltd., Kunming* 650217, *China*
2. *College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
3. *Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi* 712100, *China*)

Abstract: Soil moisture is the key to the study of energy and material exchange in the soil-plant-atmosphere circulatory system. Using the scale conversion method to push up the remote sensing data from the UAV to correct the satellite data can effectively improve the accuracy of the satellite remote sensing inversion model. Taking Hetao Irrigation Area as the research object, the resampling and TsHARP scale-up method were adopted respectively, and algorithms such as multiple linear regression (MLR), BP neural network (BPNN) and support vector machine (SVM) were introduced to construct UAV-satellite scale-up soil moisture content inversion model under different soil depths. The research results showed that the overall accuracy of the resampling scale-up method was SVM, MLR and BPNN from high to low in different soil depths, among which the SVM model was the best when the soil depth was 0~60 cm, R^2 was 0.571, and RMSE was 0.022%. The overall accuracy of the model of TsHARP scale-up method under different soil depths was BPNN, SVM and MLR from high to low, among which the BPNN model was the best under 0~60 cm soil depth, R^2 was 0.829, and RMSE was 0.015%. Compared with the corresponding soil depth model before scaling up, both scale-up methods can

收稿日期:2022-09-26　修回日期:2023-01-16
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:马仪(1969—),男,教授级高级工程师,主要从事电网防灾和输电智能运维研究,E-mail:kmdky_my@163.com
通信作者: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

significantly improve the retrieval accuracy of soil moisture content from satellite remote sensing, but TsHARP scale-up method was better than resampling method as a whole; R^2 of resampling method was increased from 0.413 to 0.571, and RMSE was decreased from 0.026% to 0.022% (a decrease of 15.4%); R^2 of TsHARP scale-up method was increased from 0.428 to 0.829, and RMSE was decreased from 0.025% to 0.015% (a decrease of 40.0%). The research result can provide theoretical and technical support for high-precision monitoring of soil moisture in large-scale irrigation areas.

Key words: soil moisture; scale-up; GF-1; UAV; monitor model

0 引言

我国西北内陆干旱半干旱区域一直存在明显的水资源短缺问题,发展缺水地区地表土壤水分快速、合理、高精度的监测,对于指导农业生产建设、荒漠植被恢复以及灌溉制度制定有着重要的作用和意义。传统的土壤水分含量测量方法大多针对地面采样点进行研究,虽然精度较高,但该方法不仅测量的范围有限,取样的代表性较差,更需耗费大量的人力、物力和财力,同时也无法实现大范围、高效率的测量效果[1]。而遥感因其具有无损、便捷快速、可进行大范围监测等优势,逐渐开始应用于地表土壤水分的监测研究。早在 20 世纪 70 年代,美欧等国家便开始利用卫星遥感进行土壤水分的监测研究[2]。虽然取得了不少进展,但受限于平台,往往难以获得大尺度范围和高精度两者兼具的监测结果。无人机(Unmanned aerial vehicle,UAV)是一种能携带多种任务设备,兼具低成本、低损耗、可重复使用等优点的无人驾驶航空器[3],当在该航空器上装载多光谱或高光谱传感器时便可以快速、较低成本、便捷灵活地获取高精度的农田作物信息,以满足精准农业的相关需求[4],但作用的尺度范围较小。一般而言,单独利用卫星或无人机遥感无法实现高精度且大尺度范围的土壤水分监测,因此有必要发展合理的尺度转换方法将二者的优势结合,以快速实现大尺度范围上高精度的地表地物信息监测。在遥感领域,尺度转换就是将数据或信息从一个尺度变换到另一个尺度的过程,将从高分辨率到低分辨率的尺度转换称为升尺度,反之则称为降尺度[5]。采用尺度转换方法将多源遥感数据相结合以监测地表土壤水分和盐分的可行性已被诸多学者验证。如冯文哲等[6]分别利用卫星和无人机获取遥感影像数据,引入多种机器学习算法构建土壤盐渍化监测模型,并使用升尺度转换方法,较大幅度地提高了卫星遥感对土壤盐渍化的监测精度。岳朝政[7]提出了基于变分贝叶斯推断和非参数贝叶斯的土壤水分空间升尺度法。陈俊英等[8]以卫星和无人机两种不同遥感为数据源,采用改进的 TsHARP 法进行线性回归函数趋势面的构造以构建土壤盐渍化监测模型,提高了卫星遥感对土壤盐渍化的监测精度。张智韬等[9]基于加权算法将无人机数据尺度上推以修正卫星遥感数据,有效提高了土壤含盐量监测精度。土壤中的水分和盐分常常相互伴随交互、联系紧密[10],如柯增鸣[11]发现在 0~20 cm 和 20~40 cm 土层的土壤水分与土壤盐分在土壤相对含水率为 52%~75%下具有较高的相关性,张术伟等[12]在探究黄河三角洲壤土水盐变化时发现,在升盐过程中,土壤表层水盐呈现正向线性关系,此外土壤中的水分和盐分在光谱吸收带的范围有着较大的重合[10],理论上可以采取尺度转换手段将多源遥感数据相结合的方式,应用于土壤水分的监测研究。然而,目前在协同多源遥感数据以开展升尺度的土壤水分监测方面的相关研究仍较少。基于此,本研究以内蒙古河套灌区为研究对象,分别采用重采样和 TsHARP 升尺度法,将无人机遥感数据尺度上推以修正卫星数据,通过引入不同算法构建升尺度修正后 GF-1 卫星遥感数据源下不同深度的土壤含水率反演模型,以期实现大尺度、高精度的土壤水分反演,为干旱、半干旱地区的土壤含水率监测提供技术依据。

1 材料与方法

1.1 研究区概况

选取内蒙古河套灌区解放闸灌域沙壕渠试验站为研究区。河套灌区位于我国黄河流域上游,平均海拔 1 km 以上,是我国第三大灌区[13]。解放闸灌域处于河套灌区西部,属干旱半干旱区[14]。而沙壕渠是解放闸灌域的一个独立体,位于内蒙古自治区巴彦淖尔市杭锦后旗,其土壤类型大多为粉质粘壤土,平均干容重约为 1.46 t/m^3,年降水量不到 200 mm,年蒸发量却在 2 000 mm 以上,蒸降比超过 10[15]。由于气候、地形条件、土质因素及人为的不合理灌溉等因素,导致该地区的土壤盐渍化问题较为突出。

本次试验在沙壕渠内进行(图 1),在研究区内分散选取了 4 块土地,进行了无人机飞行试验,并均匀布置采样点,同步采集土壤样本,以计算土壤含水率。

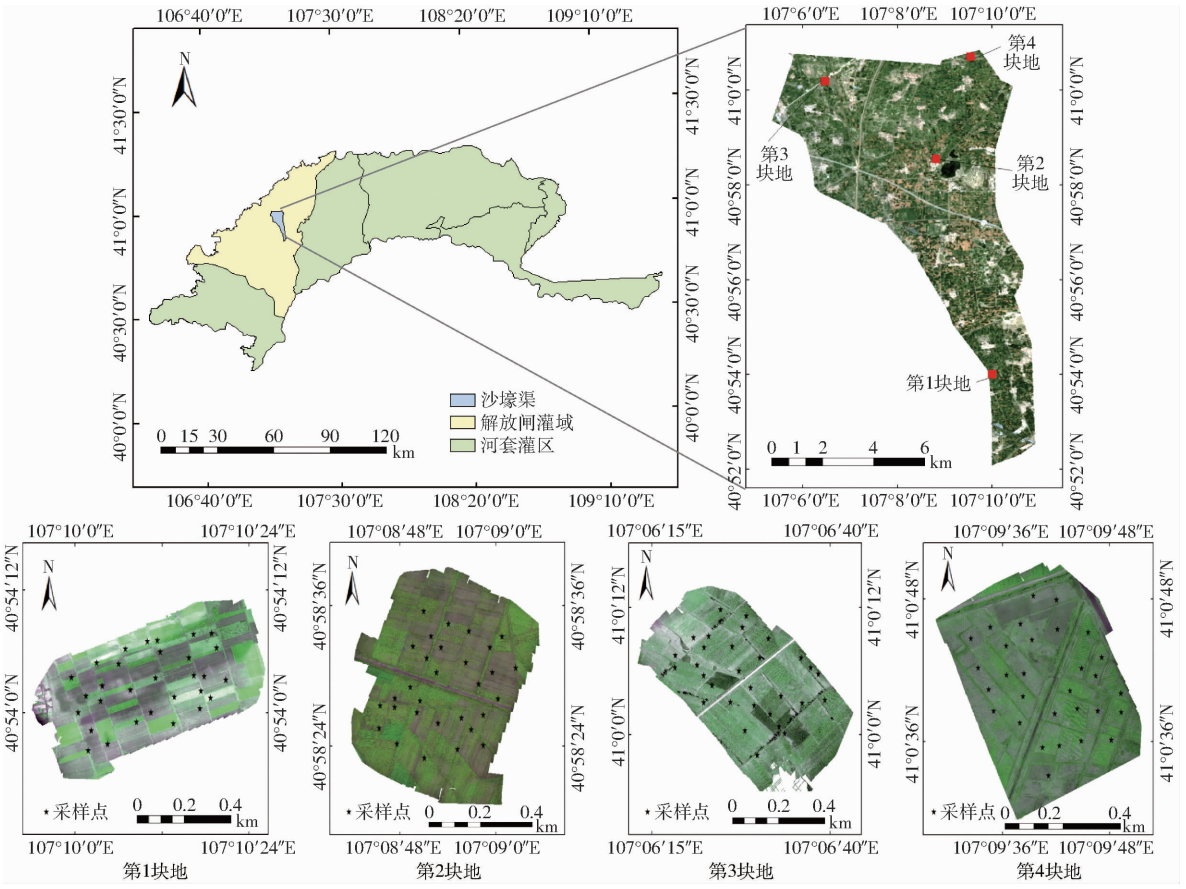

图 1　研究区示意图

Fig. 1　Schematic of research area

1.2　遥感数据获取与处理

1.2.1　卫星遥感数据

卫星影像数据从中国资源卫星应用中心(http://www.cresda.com/CN/)下载获取。本研究选用的卫星遥感影像成像时间为 2019 年 7 月 30 日,空间分辨率为 16 m,包括 b1、b2、b3、b4 共 4 个波段,分别对应蓝(B)、绿(G)、红(R)和近红外(NIR),谱段范围分别为 0.45 ~ 0.52 μm、0.52 ~ 0.59 μm、0.63 ~ 0.69 μm 和 0.77 ~ 0.89 μm。利用 ENVI 软件对获取的影像进行辐射定标、几何精度校正、大气校正、裁剪等预处理,之后将实测的 120 个采样点坐标导入遥感影像,提取各波段的反射率,用于后续光谱指数计算及土壤含水率反演。

1.2.2　无人机多光谱遥感数据

使用大疆创新科技有限公司生产的 M600 型六旋翼无人机获取无人机遥感影像。多光谱传感器型号为 Micro - MCA,包括 b1、b2、b3、b4、b5、b6 共 6 个光谱波段,分别对应蓝(B)、绿(G)、红(R)、红边(NIR)、近红外 1(NIR1)以及近红外 2(NIR2),中心波长分别为 490、550、680、720、800、900 nm。于 2019 年 7 月 15—25 日获取无人机多光谱影像。飞行当天天气晴朗,无人机按照定好的航线飞行,飞行高度为 120 m,多光谱相机镜头垂直向下,此时影像所对应的地面分辨率约为 0.065 m。使用多光谱相机配套的 Pixel wrench 图像编辑软件对获取的无人机遥感影像进行校正、裁剪、拼接、合成等相关处理,导出 tif 格式的多光谱影像。最后将采样点的经纬度导入 ENVI 软件,提取影像中对应采样点的灰度,通过参考白板进一步计算各波段反射率。

1.3　土壤样本采集处理与含水率计算

土壤样本的采样时间与无人机影像获取时间同步,与卫星遥感影像数据获取时间相近。采用五点取样法进行采样,共布设 120 个土壤采样点,采样点深度分别为 0 ~ 20 cm、20 ~ 40 cm 和 40 ~ 60 cm,并采用手持 GPS 定位,记录采样点的地理坐标。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,密封并标记好后称量,经 105℃、24 h 恒温处理后称量,计算土壤质量含水率 θ_m,计算式为

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

式中　W_1——空铝盒质量

W_2——湿土加铝盒质量

W_3——干土加铝盒质量

将因试验记录及计算错误所得土壤含水率为负值的数据剔除,最终剩余 101 个实测土壤样本用于

本次研究。将 101 个土壤含水率样本从小到大排序,建模集与验证集按照比例 2∶1等间隔分配,以确保建模集与验证集分布均匀。

1.4 光谱指数计算与全子集筛选

一般而言,仅用个别波段难以充分提取地物光谱信息以及构建高精度的土壤含水率反演模型,因此许多学者通过建立光谱指数以更好地反映地物信息。如曹雷等[16]研究发现,SI-T、S5 等盐分指数对土壤盐渍化较为敏感,具有较好的预测能力;差值植被指数(Difference vegetation index, DVI)常被应用于光学遥感反演土壤水分[17]。结合前人研究经验以及考虑到灌区较高植被覆盖度和一定盐渍化问题的实际情况,在 GF-1 卫星遥感数据的波段反射率基础上,引入应用广泛的植被指数和盐分指数建立遥感图像与土壤含水率的定量关系,分别为盐分指数 SI2、盐分指数 S3、盐分指数 S5、盐分指数 S6、盐分指数 SI-T、亮度指数(Brightness index, BI)、土壤调节植被指数(Soil adjusted vegetation index, SAVI2)、垂直干旱指数(Perpendicular drought index, PDI)、转换型土壤调节植被指数(Transformed soil-adjusted vegetation index, TSAVI)、差值植被指数(DVI),相关计算公式见表 1。

表 1 光谱指数汇总

Tab.1 Summary of spectral index

光谱指数	计算公式	文献序号
SI-T	$100(R-NIR)$	[16]
DVI	$NIR-R$	[18]
S3	GR/B	
S5	BR/G	[19]
S6	$RNIR/G$	
TSAVI	$a(NIR-aR-b)/(aNIR+R-ab)$	[20]
BI	$\sqrt{R^2+NIR^2}$	[21]
SI2	$\sqrt{G^2+R^2+NIR^2}$	
PDI	$(R+aNIR)/\sqrt{a^2+1}$	[22]
SAVI2	$NIR/(B+b/a)$	[23]

注:a、b 表示土壤线系数,分别设置为 1.0、0.5;B、G、R、NIR 分别为蓝、绿、红、近红外波段反射率。

采用全子集筛选法筛选出自变量(敏感波段和光谱指数)的最优组合。该法假设有 M 个自变量,对 M 中的 P 个变量($1\leqslant P\leqslant M$,P、M 均为整数)分别与因变量做最小二乘拟合,拟合出 1 ~ P 个预测变量模型;在 1 ~ P 个模型中,根据调整后决定系数(Coefficient of determination, R^2)最大原则,综合考虑均方根误差(Root mean squared error, RMSE)、赤池信息准则(Akaike information criterion, AIC)和施瓦茨信息准则(Schwarz information criterion, SIC),从 P 个模型中选出一个最优自变量组合。通过 Matlab 软件完成全子集筛选算法模型的构建。

1.5 模型建立

1.5.1 多元线性回归模型

多元线性回归(Multiple linear regression, MLR)是指在相关变量中,将一个变量视为因变量,其它一个或多个变量视为自变量,建立多个变量之间线性的数学模型数量关系式[24]。多元线性回归是一元线性回归的扩展,通常采用最小二乘法对参数进行估计。因变量 y 与自变量 X_1、X_2、…、X_n 之间线性关系为

$$y=\beta_0+\beta_1X_1+\beta_2X_2+\cdots+\beta_nX_n+\varepsilon \tag{2}$$

式中 β_0、β_1、…、β_n——回归系数

ε——服从正态独立同分布的随机误差项

通过 Matlab 软件完成多元线性回归模型的建模与验证。

1.5.2 BP 神经网络模型

BP 神经网络(Back propagation neural network, BPNN)是一种根据误差逆向传播算法训练的多层前馈神经网络[6]。该机器学习模型的拓扑结构一般由输入层、隐藏层、输出层组成,本研究采用 3 层 BP 神经网络,其中输入层与输出层均采用线性激活函数(purelin),隐含层采用双曲正切激活函数(tansig),含有 10 个神经元的单层网络,为防止数据分析因为不同的量纲得出不同的结果,对输入层和输出层数据进行归一化处理。模型的各参数设置为:训练拟合目标误差为 0.1%,网络的学习速率为 0.05,最大训练次数为 6 000 次,其余参数取默认值。通过 Matlab 软件完成 BP 神经网络模型的建模和验证。

1.5.3 支持向量机模型

支持向量机(Support vector machines, SVM)是一类按监督学习方式对数据进行二元分类的广义线性分类器,从功能上可分为分类和回归两类[25],可用于非线性分类问题[26],能够较好地避免“离散值多”的问题。本研究将目前应用广泛的径向基核(RBF)作为核函数,惩罚参数 C 和核参量 g 则通过在模型中设置循环来选择和调整,同样对输入和输出数据进行归一化处理,在 Matlab 软件进行支持向量机模型的构建和验证。

1.6 升尺度转换方法

1.6.1 重采样升尺度法

在遥感领域,重采样是一种影像数据重新组织过程中的灰度处理方法[27]。常用的重采样方法有最邻近法、双线性内插法、立方卷积内插法、像元聚合法等。本研究采用像元聚合法实现对无人机遥感影像的重采样。像元聚合法是对所有的输出像元值

有贡献的像元平均值进行采样，通过 ENVI 软件 Rezise data 功能中的 Pixel aggregate 实现。用重采样升尺度到分辨率 16 m 的无人机遥感数据构建的光谱指数修正 GF－1 卫星数据光谱指数，具体为分辨率 16 m 的无人机遥感数据的波段反射率及构建光谱指数乘以对应的 GF－1 卫星数据的波段反射率及光谱指数，得到升尺度修正后的 GF－1 卫星遥感数据。

1.6.2　TsHARP 升尺度法

TsHARP 升尺度法主要通过构造趋势面进行尺度转换，有学者将其应用于土壤盐渍化的升尺度研究[28]，但仅进行了传统的线性回归模型函数趋势面之间的构造。本文通过将目前应用广泛的 BP 神经网络和支持向量机算法进行趋势面的构造，以实现土壤水分的升尺度研究，提高卫星遥感对土壤含水率的反演，该升尺度法的主要步骤如下：

首先建立无人机尺度上土壤含水率与趋势面因子间的关系，公式为

$$S = F(B') \tag{3}$$

式中　S——无人机分辨率 0.065 m 尺度上采用趋势面因子反演的土壤含水率

F——无人机分辨率 0.065 m 尺度上趋势面反演函数或模型，同样适用于升尺度到 GF－1 卫星分辨率 16 m 尺度上土壤含水率与趋势面因子间的反演

B'——无人机分辨率 0.065 m 尺度上的趋势面因子

由于受到土壤盐分等因素的影响，趋势面因子总是很难完全反映土壤含水率的分布情况，表现为无人机高分辨率 0.065 m 尺度上的转换残差 ΔS，在本文中也认为等于 GF－1 卫星尺度上的转换残差 ΔS_1，计算公式为

$$\Delta S = S' - S = \Delta S_1 \tag{4}$$

式中　S'——实测土壤含水率

升尺度修正后 GF－1 卫星数据源下反演的土壤含水率由 GF－1 卫星数据应用无人机尺度上建立的趋势面计算的土壤含水率和卫星尺度上的转换残差构成，计算公式为

$$S_{16} = F_{16}(B_{16}) + \Delta S_1 = F(B_{16}) + \Delta S_1 \tag{5}$$

式中　S_{16}——升尺度修正后 GF－1 卫星数据下反演的土壤含水率

B_{16}——GF－1 卫星分辨率 16 m 尺度上的趋势面因子

1.7　模型精度评价指标

根据调整后的决定系数 R^2、均方根误差（RMSE）、赤池信息准则（AIC）和施瓦茨信息准则（SIC）来综合评价全子集筛选效果；通过调整后 R^2、RMSE 综合评价升尺度前后各模型的精度与稳定性。调整后 R^2 可以反映建模和验证的拟合效果，RMSE 可以反映反演值与实测值之间的偏差度，其中 R^2 越接近 1，RMSE 越小，说明模型精度越高。AIC 和 SIC 能够在一定程度上衡量统计模型的复杂度和拟合优良性，其参数值越小表示该模型能够以最少自由变量最好地解释因变量。

2　结果与分析

2.1　相关性分析与全子集筛选确定的最优自变量组合

将 GF－1 卫星遥感数据的波段反射率和光谱指数分别与实测土壤含水率进行皮尔逊相关性分析，以初步分析实测土壤含水率与不同光谱因子之间的密切程度，结果如图 2 所示。其中，深度 0～40 cm 为 0～20 cm 和 20～40 cm 土壤含水率的平均值，深度 0～60 cm 为 0～20 cm、20～40 cm 和 40～60 cm 土壤含水率的平均值。

参考相关系数检验临界值表进行显著性检验，当样本数据点为 101 时，其对应的自由度为 99，当相关系数的绝对值大于 0.255 时，达到 0.01 显著性水平。从图 2 可以看出，除 b3、S5、DVI 和 SI－T 外，其它波段及光谱指数与土壤含水率的相

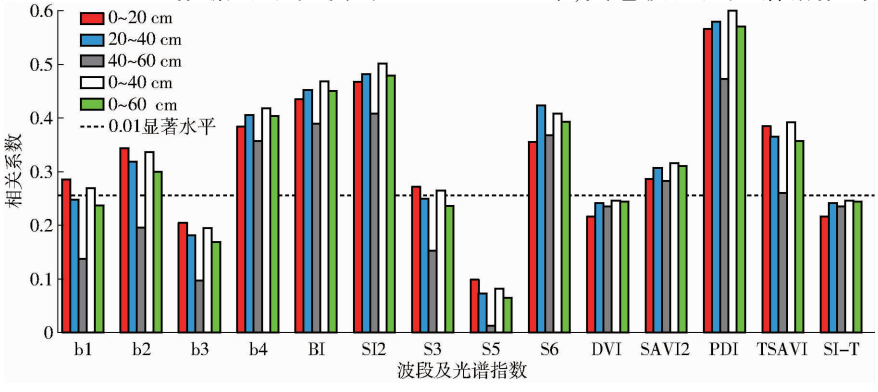

图 2　波段及光谱指数与不同深度土壤含水率的皮尔逊相关系数

Fig. 2　Pearson correlation coefficient of band and spectral index and soil moisture content at different depths

关系数大于 0.255,达到 0.01 显著水平,分析认为绿波段 b2 位于绿色植物的绿色反射率附近,对植物的绿反射敏感;而近红外波段 NIR 处于植物的高反射区,为植物识别通用波段,与土壤含水率相关性较强,故 b2、NIR 波段及基于该两波段建立的 BI、SI2、SAVI2、PDI 等光谱指数与土壤含水率表现出较强的相关性。相较于其它深度土壤含水率,深度40 ~ 60 cm 的土壤含水率与各波段及光谱指数的相关系数更小,并未表现出较强的相关性,这与文献[29]研究结果一致,可能原因是随着土壤深度增加,土壤内部环境情况越发复杂,遥感作用于土层的能力逐渐下降。

将波段反射率和光谱指数作为自变量,实测土壤含水率为因变量,构建全子集筛选算法模型,根据验证集调整后 R^2 最大原则,综合考虑 RMSE、AIC 和 SIC 等评价指标,确定不同深度下波段反射率与光谱指数之间的最优变量组合,结果如表 2 所示。

表 2 基于全子集筛选的 GF-1 卫星数据源下最优变量组合

Tab. 2 Optimal variable combination under GF-1 satellite data source based on full subset screening

土壤深度/cm	自变量个数	最优组合	R^2	RMSE/%	AIC	SIC
0 ~ 20	2	b2、SI - T	0.406	0.035	0.104	0.194
	3	b3、b4、PDI	0.413	0.035	0.163	0.298
	4	b3、DVI、PDI、TSAVI	0.423	0.035	0.222	0.401
	5	b3、BI、S5、DVI、PDI	0.447	0.036	0.281	0.505
	6	b1*、b3*、b4*、SI2*、S3*、PDI*	0.464	0.034	0.339	0.609
20 ~ 40	2	S3*、SI - T*	0.235	0.036	0.104	0.194
	3	S3、TSAVI、SI - T	0.102	0.039	0.164	0.298
	4	SI2、S3、DVI、TSAVI	0.096	0.039	0.223	0.402
	5	b1、SI2、S3、S6、SAVI2	0.113	0.038	0.281	0.506
	6	b1、SI2、S3、S6、PDI、SAVI2	0.142	0.038	0.340	0.609
40 ~ 60	2	b4*、SAVI2*	0.133	0.031	0.103	0.193
	3	b3、S3、S6	0.110	0.031	0.162	0.297
	4	b3、S3、S5、S6	0.116	0.031	0.221	0.401
	5	b3、S3、S5、S6、TSAVI	0.116	0.031	0.280	0.504
	6	b4、b3、DVI、SAVI2、PDI、SI - T	0.051	0.032	0.339	0.608
0 ~ 40	2	S3、SI - T	0.353	0.032	0.104	0.194
	3	S3、TSAVI、SI - T	0.347	0.033	0.163	0.297
	4	b3、b4、S5、PDI	0.324	0.033	0.222	0.401
	5	b3、b4、S5、PDI、TSAVI	0.342	0.033	0.280	0.505
	6	b3*、b4*、BI*、S3*、S5*、PDI*	0.356	0.032	0.339	0.608
0 ~ 60	2	S3*、DVI*	0.429	0.025	0.102	0.192
	3	b1、S5、S6	0.368	0.027	0.161	0.296
	4	b1、b3、S3、S6	0.405	0.026	0.220	0.399
	5	b4、S3、S5、DVI、PDI	0.418	0.026	0.279	0.503
	6	b1、b2、b3、S3、S6、TSAVI	0.411	0.026	0.337	0.607

注:* 表示不同深度下筛选的最优变量组合。

从表 2 可以看出,0 ~ 20 cm、0 ~ 40 cm 和 0 ~ 60 cm 3 个深度下的 R^2 达 0.324 以上,其中0 ~ 20 cm 和 0 ~ 60 cm 整体达 0.368 以上,拟合效果较好;而深度 40 ~ 60 cm 下的 R^2 仅有 0.10 左右,拟合效果较差,原因可能是该深度土壤含水率与各光谱变量的相关性较差。各深度下的 AIC 和 SIC 均随着自变量个数的增多而呈现逐渐上升的趋势,这是因为随着自变量个数的增加,模型的拟合效果可能会有所提升,但会受到一定的“惩罚”。各深度下的 RMSE 大多在 0.03% 上下波动变化,且随着 R^2 的增大呈现减小趋势。不同深度的敏感光谱特征变量总体上是一致的,每一种光谱特征变量在其它深度中均有出现,如 S3、DVI 等,在不同深度最优变量组合的选择上以最大 R^2 为首要考虑条件(RMSE 与此同时也最小)进行。如深度 0 ~ 20 cm 下自变量个数为 6 时其 R^2 最大,RMSE 最小,故选择 b1、b3、b4、SI2、S3 和 PDI 作为该深度下的最优变量组合,同理筛选出深度 20 ~ 40 cm 的最优变量组合为 S3、SI - T;深度 40 ~ 60 cm 的最优变量组合为 b4、SAVI2;深度0 ~ 40 cm 的最优变量组合为 b3、b4、BI、S3、S5、PDI;深度 0 ~ 60 cm 的最优变量组合为 S3、DVI。

2.2 基于重采样升尺度法的不同深度土壤含水率反演模型

采用全子集筛选法对升尺度修正后的波段反射率和光谱指数组成的自变量与实测土壤含水率构成的因变量所构建的模型进行一一列举，通过验证集调整后 R^2 最大原则，综合考虑 RMSE、AIC 和 SIC 等评价指标，筛选出不同深度下的最优自变量组合，结果如下：0 ~ 20 cm 为 b1、S3、S6、TSAVI，20 ~ 40 cm 为 b1、b3、S3，40 ~ 60 cm 为 b1、b2、b3、b4、S3、SAVI2，0 ~ 40 cm 为 b2、b3、S3、S6、SI - T，0 ~ 60 cm 为 b2、S3、S5、S6、SI - T。

以全子集筛选出的升尺度修正后 GF - 1 卫星数据下的最优变量组合为自变量，实测土壤含水率为因变量，运用多元线性回归、BP 神经网络以及支持向量机算法构建不同深度下土壤水分反演模型，并与直接采用 GF - 1 卫星数据源构建的土壤水分反演模型进行对比，评价升尺度修正前后 GF - 1 卫星遥感对土壤含水率的反演效果。

2.2.1 多元线性回归模型

由表 3 可知，升尺度修正后的 0 ~ 20 cm 和 40 ~ 60 cm MLR 模型的反演精度较升尺度修正前有明显的提升，二者验证集的 R^2 分别提高 0.211、0.180，分析认为重采样中的像元聚合（Pixel aggregate）对输出的所有有贡献的像元做了取均值处理，能够一定程度上减小建模集与验证集划分不均的影响。土壤深度 0 ~ 40 cm 的反演效果较好，模型的 R^2 达到 0.530，RMSE 为 0.028%。与升尺度修正前相比，5 种深度模型的反演精度均有较为明显的提高，RMSE 有一定程度上的降低，说明该升尺度方法有效。

表 3　重采样法下不同深度土壤含水率的多元线性回归模型精度

Tab. 3　Precision of MLR model of soil moisture content at different depths by resampling method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.408	0.027	0.249*	0.033	0.452	0.027	0.460*	0.029
20 ~ 40	0.424	0.030	0.357	0.032	0.489	0.027	0.436	0.030
40 ~ 60	0.272*	0.027	0.161*	0.030	0.394*	0.024	0.341*	0.024
0 ~ 40	0.412*	0.028	0.405*	0.029	0.528*	0.026	0.530*	0.028
0 ~ 60	0.313	0.026	0.415	0.025	0.486	0.023	0.564	0.023

注：* 表示反演模型精度对比提升明显，下同。

2.2.2 BP 神经网络模型

由表 4 可知，升尺度修正后 GF - 1 卫星数据下的各深度 BPNN 模型的 R^2 整体提高 0.11 左右，部分深度如 0 ~ 20 cm 和 0 ~ 60 cm BPNN 模型的 R^2 提高 0.15 左右，RMSE 整体在 0.031% 以下，均比升尺度修正前明显降低。各深度 BPNN 模型建模集与验证集的 R^2 相近，无过拟合或欠拟合现象，模型的拟合效果较好。升尺度修正后的 40 ~ 60 cm BPNN 模型的反演精度 R^2 明显低于其它深度，建模与验证效果较差，不适宜进行土壤含水率反演。

表 4　重采样法下不同深度土壤含水率的 BP 神经网络模型精度

Tab. 4　Precision of BPNN model of soil moisture content at different depths by resampling method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.338	0.030	0.356	0.033	0.475	0.027	0.471	0.030
20 ~ 40	0.387*	0.030	0.358*	0.033	0.503*	0.027	0.424*	0.031
40 ~ 60	0.144*	0.029	0.167*	0.030	0.255*	0.027	0.261*	0.028
0 ~ 40	0.418*	0.028	0.388*	0.032	0.524*	0.026	0.512*	0.028
0 ~ 60	0.331	0.026	0.428	0.025	0.484	0.023	0.493	0.024

2.2.3 支持向量机模型

由表 5 可知，在 5 种不同深度的升尺度修正后 SVM 模型中，0 ~ 40 cm 和 0 ~ 60 cm SVM 模型的 R^2 较升尺度修正前提升最明显，其中，0 ~ 40 cm SVM 模型的 R^2 提升 0.176；0 ~ 60 cm SVM 模型的 R^2 提升 0.158，R^2 达到 0.571，RMSE 降低至 0.022%，降幅 15.4%，为最优深度反演，而其它 3 个深度 SVM 模型的反演精度也有明显幅度的提高。升尺度修正后 GF - 1 卫星数据下部分深度 SVM 模型的反演精度 R^2 最大能提高近 0.176，RMSE 对应升尺度修正前有较为明显的降低，表明该升尺度法能提高 GF - 1 卫星遥感对土壤含水率的反演精度。

表 5　重采样法下不同深度土壤含水率的支持向量机模型精度

Tab. 5　Precision of SVM model of soil moisture content at different depths by resampling method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.437	0.028	0.343	0.033	0.459	0.027	0.455	0.030
20 ~ 40	0.432	0.029	0.248	0.035	0.490	0.028	0.375	0.032
40 ~ 60	0.179	0.029	0.178	0.030	0.284	0.027	0.225	0.029
0 ~ 40	0.361*	0.030*	0.357*	0.032*	0.537*	0.025*	0.533*	0.028*
0 ~ 60	0.414*	0.024*	0.413*	0.026*	0.569*	0.021*	0.571*	0.022*

2.3 基于 TsHARP 升尺度法的不同深度土壤含水率反演模型

由 2.1、2.2 节可知，深度 40 ~ 60 cm 下各土壤

水分反演模型的建模效果明显较其它深度差,不适宜进行土壤水分反演。实际上,随着土层深度的增加,遥感作用于地表的能力逐渐下降,越深处的土壤水分反演显然不合理甚至是错误的。因此,在本节 TsHARP 升尺度法中只进行深度 0 ~ 20 cm、20 ~ 40 cm、0 ~ 40 cm 及 0 ~ 60 cm 土壤含水率反演模型的建立与分析。

2.3.1 多元线性回归模型

由表 6 可知,与升尺度修正前相比,各深度模型的反演精度有较为明显的提高,除 0 ~ 20 cm MLR 模型外,其它3 种深度模型 R^2 整体从 0.4 左右提升至 0.5 以上。其中,0 ~ 20 cm MLR 模型验证集的 R^2 较升尺度修正前提升 0.141,0 ~ 60 cm MLR 模型建模集的 R^2 较升尺度修正前提升 0.213,提升幅度明显。升尺度修正后的各深度 MLR 模型的 RMSE 整体有所降低,说明该升尺度法在提高 GF - 1 卫星遥感对土壤水分的反演精度可行。

表 6 TsHARP 升尺度法下不同深度土壤含水率的多元线性回归模型精度

Tab.6 Precision of MLR model of soil moisture content at different depths by TsHARP scale-up method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.408	0.027	0.249	0.033	0.458	0.027	0.390	0.028
20 ~ 40	0.424	0.030	0.357	0.032	0.534	0.028	0.494	0.031
0 ~ 40	0.412	0.028	0.405	0.029	0.506	0.027	0.456	0.031
0 ~ 60	0.313	0.026	0.415	0.025	0.526	0.023	0.403	0.026

2.3.2 BP 神经网络模型

由表 7 可知,除 0 ~ 40 cm BPNN 模型外,其它 3 种深度模型的反演精度 R^2 整体达到 0.7 以上,较升尺度修正前显著提高,RMSE 整体下降明显。其中升尺度修正后的 0 ~ 60 cm BPNN 模型的 R^2 最高提升至 0.829,RMSE 最低降至 0.015%,降幅达到 40%,为最优反演。与 2.3.1 节 MLR 模型相比,各深度BPNN模型的反演效果有着显著的改善,明显优于多元线性回归算法,说明运用 BP 神经网络算法构建趋势面可行,TsHARP 升尺度法的优势能得以较好地展现。

表 7 TsHARP 升尺度法下不同深度土壤含水率的 BP 神经网络模型精度

Tab.7 Precision of BPNN model of soil moisture content at different depths by TsHARP scale-up method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.338	0.030	0.356	0.033	0.745	0.023	0.739	0.023
20 ~ 40	0.387	0.030	0.358	0.033	0.814	0.028	0.746	0.028
0 ~ 40	0.418	0.028	0.388	0.032	0.692	0.021	0.672	0.023
0 ~ 60	0.331	0.026	0.428	0.025	0.786	0.015	0.829	0.015

2.3.3 支持向量机模型

由表 8 可知,升尺度修正后 4 种深度 SVM 模型的 R^2 达到 0.6 以上,与升尺度修正前相比有明显提高;除 20 ~ 40 cm SVM 模型验证集外,其它深度模型的 RMSE 均对应升尺度修正前明显降低。其中,0 ~ 20 cm、0 ~ 40 cm 和 0 ~ 60 cm SVM 模型 R^2 较升尺度修正前提升最明显。与 2.3.2 节基于 BP 神经网络算法的 TsHARP 升尺度法在提高反演模型精度上所得结论相似,运用支持向量机的机器学习算法构造趋势面能有效发挥 TsHARP 升尺度法的效果以提高模型反演精度。

表 8 TsHARP 升尺度法下不同深度土壤含水率的支持向量机模型精度

Tab.8 Precision of SVM model of soil moisture content at different depths by TsHARP scale-up method

土壤深度/cm	升尺度修正前				升尺度修正后			
	建模集		验证集		建模集		验证集	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
0 ~ 20	0.437	0.028	0.343	0.033	0.773	0.019	0.712	0.024
20 ~ 40	0.432	0.029	0.248	0.035	0.639	0.023	0.407	0.035
0 ~ 40	0.361	0.030	0.357	0.032	0.615	0.023	0.621	0.026
0 ~ 60	0.414	0.024	0.413	0.026	0.765	0.016	0.672	0.022

2.4 升尺度反演模型综合评价

由于基于 TsHARP 升尺度法的修正后 GF - 1 卫星数据下只进行了深度 0 ~ 20 cm、20 ~ 40 cm、0 ~ 40 cm 和 0 ~ 60 cm 土壤含水率的反演,故以下主要对比这 4 种不同深度在基于重采样和 TsHARP 升尺度法的修正后 GF - 1 卫星数据下构建的土壤含水率反演模型。将两种升尺度方法下采用不同算法构建的不同深度土壤含水率反演模型的评价指标 R^2 绘制成柱形图,以直观对比不同深度不同模型的反演精度,结果如图 3 所示。

由图 3 可知,重采样升尺度法下 SVM 模型的反演精度最高,而 MLR 模型整体略优于 BPNN 模型,即精度由高到低依次为 SVM、MLR、BPNN;TsHARP 升尺度方法下采用 BPNN 和 SVM 两种机器学习算法构建的反演模型均优于 MLR 算法,而 BPNN 算法又整体优于 SVM 算法,即精度由高到低依次为 BPNN、SVM、MLR。

采用机器学习算法的 TsHARP 升尺度法构建的

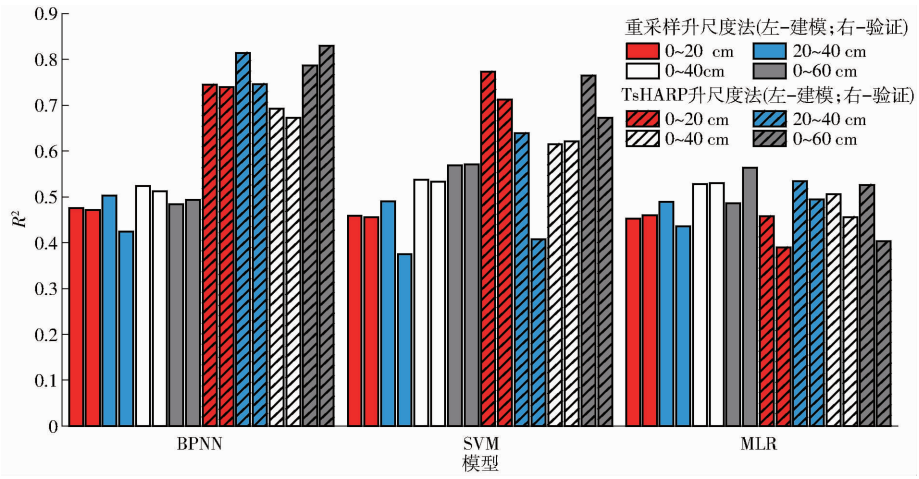

图 3　基于两种升尺度法的不同深度下土壤含水率反演模型对比

Fig. 3　Comparison of soil moisture inversion models at different depths based on two scale-up methods

反演模型精度较高且明显优于基于多元线性回归算法，TsHARP 升尺度法下反演模型的 R^2 可达 0.7 以上，说明采用 BPNN 和 SVM 算法构造趋势面进行升尺度转换可行。

对于基于多元线性回归算法的重采样和 TsHARP 升尺度法中，两种不同升尺度法下的不同深度 MLR 模型的反演精度整体相差不大，而 TsHARP 升尺度法下的 4 种不同深度 BPNN 和 SVM 模型的反演精度 R^2 均明显高于基于重采样升尺度法（重采样升尺度法下反演模型最大 R^2 约为 0.57），说明 TsHARP 升尺度法整体上优于重采样升尺度法。

2.5　沙壕渠灌域土壤含水率反演

由上述可知，TsHARP 升尺度法下 0 ~ 60 cm BPNN 模型的反演效果最好，故选用该模型反演河套灌区内整个沙壕渠的土壤含水率空间分布情况，结果如图 4 所示。

由图 4 可知，土壤含水率在 0 ~ 10%、10% ~ 15%、15% ~ 20% 和大于 20% 分别约占整个沙壕渠研究区的 15%、38%、24% 和 23%，根据内蒙古土壤墒情类型及其含水率等级指标[30]，认为土壤含水率低于 15% 时便出现干旱，而沙壕渠灌域约有 53% 的区域的土壤含水率低于 15%（主要分布在中部、西北部和南部），说明整个沙壕渠灌域较为干旱缺水，这与该区域处于西北内陆干旱半干旱区、整体缺乏水资源的实际情况相符。同时也可以看到沙壕渠土壤含水率高于 15% 的区域占比约 47%，其原因可能是 7 月下旬气温较高，作物需水量较大，灌区进行了较多次的人为引水灌溉以保证作物生长发育所需的水分，故该时间段内作物种植区域的土壤水分含量能维持在一定水平。

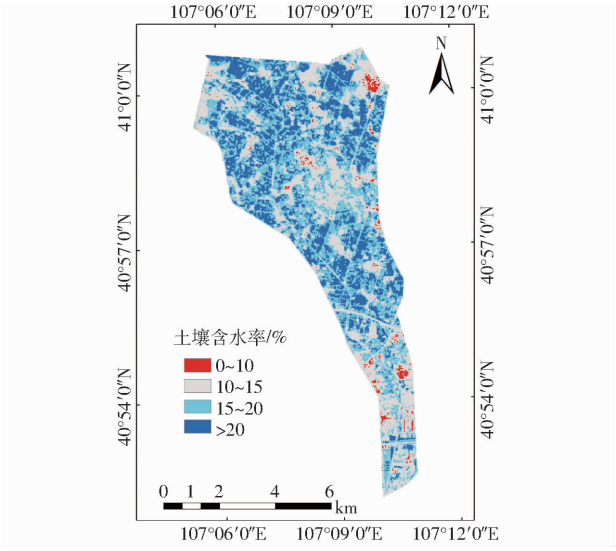

图 4　沙壕渠土壤含水率反演结果

Fig. 4　Inversion result of soil moisture content in Shahaoqu

3　讨论

本文旨在分析升尺度修正前后 GF-1 卫星遥感数据源下不同波段及光谱指数与不同深度土壤含水率之间的统计关系，建立土壤水分反演模型，为灌区进行农业生产及干旱监测提供依据。一般而言，受限于遥感平台，仅基于单一的低、中等分辨率的卫星遥感在大尺度范围上反演表层土壤水分和盐分的能力较为有限。如张智韬等[9]利用 GF-1 卫星遥感反演沙壕渠灌域农田表层土壤盐分，其构建的反演模型的精度 R^2 在 0.14 ~ 0.31 之间。姚一飞等[17]利用 GF-1 卫星遥感对河套灌区不同土层深度农田土壤水分进行了反演，反演模型的 R^2 大多位于 0.4 上下，部分深度反演模型的最大 R^2 为采用机器学习算法构建所得，R^2 达到 0.5 左右，RMSE 在 0.025% 上下。而本研究通过采用重采样和 TsHARP 升尺度法将无人机遥感数据上推以修正 GF-1 卫星

遥感数据,构建不同土壤深度下无人机-卫星升尺度土壤水分反演模型,显著提高了卫星遥感在大尺度范围上对地表表层土壤水分的反演精度。其中,在TsHARP 升尺度法中,相对基于传统的多元线性回归算法,将目前应用广泛的 BP 神经网络和支持向量机两种机器学习算法进行趋势面的构造,不同深度反演模型的 R^2 整体由 0.4 提高至 0.7 以上,RMSE 整体由 0.025% 降低至 0.015%,大幅度提高了 GF-1 卫星对表层土壤水分的监测精度。由此可见,通过采用较低成本的无人机遥感工具辅助协同卫星遥感并进行合理的尺度转换,能有效提高卫星遥感在大尺度上对地表地物信息的监测,从而解决单一卫星遥感在大尺度范围监测地物信息精度不高的问题,具有一定的研究意义和实际应用价值。

本研究中,土壤深度 0~60 cm 和 0~40 cm 下的反演效果整体优于其它 3 种深度,其中 0~60 cm 略优于 0~40 cm,深度 0~20 cm 和 20~40 cm 次之,深度 40~60 cm 反演效果最差,其原因主要是 7 月末为作物(葵花、玉米等)苗期结束、拔节期伊始时节,作物的大部分根系已向下伸展至深度 60 cm,此时作物根系主要在距地表土壤深度 0~50 cm 下进行水分的吸收[31],在深度 0~40 cm 和 0~60 cm 处的根系对土壤水分更为敏感[32],从而表现出最佳的反演效果;而 0~20 cm 浅表层处的土壤水分容易受到太阳辐射、降水、风速等外界自然条件变化影响,在短时间内土壤水分难以维持一个相对稳定的状态,其在土壤样本采集试验与卫星成像间隔期间土壤水分已发生了变化,一定程度上失去了影响成像时刻的真实土壤水分。如张智韬等[33]基于 TM5 和 TM7 数据,采用归一化土壤湿度指数监测宝鸡峡二支渠灌区不同深度土壤含水率,得出的最佳监测深度为 0~40 cm 和 0~60 cm,优于 0~20 cm 和 0~10 cm;屈创[34]基于 LandsatETM + 和 ASTER 两种不同遥感数据,采用温度植被干旱指数法反演白龙江流域不同深度土壤水分,也得出深度 0~40 cm 和 0~60 cm 的反演精度高于 0~20 cm 的结论(野外实测土壤水分时间和卫星成像时刻间隔 7 d);姚一飞等[17]基于 GF-1 卫星遥感对河套灌区不同土层深度农田土壤水分进行反演,同样得到土壤深度 0~40 cm 和 0~60 cm 的反演效果优于浅层 0~20 cm 的相似结论(野外实测土壤水分与卫星成像时刻存在间隔)。因此,在今后的研究中应尽量保证野外实测资料与遥感影像成像时间的同步,以减少影像成像时刻土壤含水率的真值丢失,从而提高浅层土壤水分的反演精度。

本研究仍存在一些不足,需要进一步深入探索。如光谱指数的选择是否最佳以及未采用另一种或多种变量筛选方法进行对比,所得的各深度最优变量组合实际上未必最优。此外,所建模型算法也仅是对波段及光谱指数与土壤含水率之间进行数量上的相关统计分析,这两者之间是否存在其它内在机理等联系仍有待探索[35],未来可着重在这方面上进行深入研究。内蒙古河套灌区作为本文的研究区,土壤盐渍化问题较为突出,而水分中常常含有各种盐分,且二者之间的运移[36-37]、交互等作用复杂[38],需要从物理学、化学机制以及数学模型等进一步分析盐分的影响并采取合理的方法进行剔除,故本研究所得结论的普适性还有待进一步探索。重采样和 TsHARP 升尺度法各有其特点和优势,未来可根据实际情况考虑将两种升尺度方法结合,以实现更为全面、合理的升尺度研究。

4 结论

(1)基于两种升尺度方法下的各深度 MLR、BPNN 和 SVM 模型的 R^2 均较修正前较明显提高,各模型的 RMSE 均对应升尺度修正前明显降低。其中,重采样升尺度法在土壤深度 0~60 cm 下采用 SVM 模型最优,R^2 达到 0.571,RMSE 为 0.022%;TsHARP 升尺度法在土壤深度 0~60 cm 下采用 BPNN 模型最优,R^2 达到 0.829,RMSE 为 0.015%。

(2)重采样升尺度法在不同土壤深度下模型整体精度由高到低依次为 SVM 模型、MLR 模型、BPNN 模型,TsHARP 升尺度法在不同土壤深度下模型整体精度由高到低依次为 BPNN 模型、SVM 模型、MLR 模型,5 种不同深度土壤下反演效果由高到低依次为 0~60 cm、0~40 cm、0~20 cm、20~40 cm、40~60 cm。

(3)与升尺度修正前对应土壤深度模型对比,两种升尺度方法均能明显提高卫星遥感对土壤含水率的反演精度,但 TsHARP 升尺度法整体优于重采样法;重采样法的 R^2 由 0.413 提升至 0.571,RMSE 由 0.026% 降至 0.022%(降幅 15.4%);TsHARP 升尺度法的 R^2 由 0.428 提升至 0.829,RMSE 由 0.025% 降至 0.015%(降幅 40.0%)。

参 考 文 献

[1] 金希. 高分辨率 SAR 影像裸土信息提取及土壤含水量反演初探[D]. 杭州:浙江大学,2011.
JIN Xi. A preliminary study on bare soil extraction and its moisture retrieval from high resolution SAR data[D]. Hangzhou:

Zhejiang University, 2011. (in Chinese)
[2] 高琪. 基于多源遥感数据的南疆干旱区荒漠土壤水分监测研究[D]. 阿拉尔:塔里木大学,2021.
GAO Qi. Soil moisture in the desert of South Xinjiang Arid Zone based on multi-source remote sensing data remote sensing monitoring research[D]. Alar: Tarim University, 2021. (in Chinese)
[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(1):88-92.
JIN Wei, GE Hongli, DU Huaqiang, et al. A review on unmanned aerial vehicle remote sensing and its application[J]. Remote Sensing Information, 2009(1): 88-92. (in Chinese)
[4] 刘倩,梁志海,范慧芳. 浅谈无人机遥感的发展及其行业应用[J]. 测绘与空间地理信息, 2016, 39(6): 167-169.
LIU Qian, LIANG Zhihai, FAN Huifang. The development of UAV remote sensing and its application in geo-information related industries[J]. Geomatics & Spatial Information Technology, 2016, 39(6): 167-169. (in Chinese)
[5] 吴骅,姜小光,习晓环,等. 两种普适性尺度转换方法比较与分析研究[J]. 遥感学报,2009,13(2):183-189.
WU Hua, JIANG Xiaoguang, XI Xiaohuan, et al. Comparison and analysis of two general scaling methods for remotely sensed information[J]. Journal of Remote Sensing, 2009,13(2):183-189. (in Chinese)
[6] 冯文哲,王新涛,韩佳,等. 基于卫星和无人机遥感数据尺度转换的土壤盐渍化监测研究[J]. 节水灌溉,2020(11):87-93.
FENG Wenzhe, WANG Xintao, HAN Jia, et al. Research on soil salinization monitoring based on scale conversion of satellite and UAV remote sensing data[J]. Water Saving Irrigation,2020(11):87-93. (in Chinese)
[7] 岳朝政. 基于贝叶斯模型的土壤水分空间尺度上推方法[D]. 南昌:华东交通大学,2018.
YUE Chaozheng. Spatial up-scaling method of soil moisture based on Bayesian model[D]. Nanchang: East China Jiaotong University, 2018. (in Chinese)
[8] 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)
[9] 张智韬,陈钦达,黄小鱼,等. 基于加权算法的空-天遥感升尺度土壤含盐量监测模型[J]. 农业机械学报,2022,53(9):226-238.
ZHANG Zhitao, CHEN Qinda, HUANG Xiaoyu, et al. UAV-satellite remote sensing scale-up monitoring model of soil salinity based on dominant class variability-weighted method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 226-238. (in Chinese)
[10] 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. Effect of water-salt interaction on soil spectral characteristics in Hetao Irrigation Area of Inner Mongolia, China[J]. Transactions of the CSAE, 2020,36(18):153-164. (in Chinese)
[11] 柯增鸣. 黄土丘陵区治沟造地新造耕地水盐空间分布及运移机制[D]. 杨凌:西北农林科技大学,2022.
KE Zengming. Spatial distribution and migration mechanism of soil water and salt in the newly cultivated land after the project of gully land consolidation in Loess Hilly Area[D]. Yangling: Northwest A&F University, 2022. (in Chinese)
[12] 张术伟,常春艳,王卓然,等. 黄河三角洲不同盐度壤土表层水盐关系研究[J]. 黑龙江农业科学,2022(7):43-49.
ZHANG Shuwei, CHANG Chunyan, WANG Zhuoran, et al. Study on surface water-salt relationship of loam soil with different salinities in Yellow River Delta[J]. Heilongjiang Agricultural Sciences, 2022(7):43-49. (in Chinese)
[13] 李焕弟,李江,刘永,等. 内蒙古河套灌区土壤性质空间变异性分析——以解放闸灌域和永济灌域为例[J]. 水资源与水工程学报, 2021,32(6): 215-221.
LI Huandi, LI Jiang, LIU Yong, et al. Spatial variability of soil properties in Hetao Irrigation Area in Inner Mongolia—a case study in Jiefang Sluice Irrigation Area and Yongji Irrigation Area[J]. Journal of Water Resources and Water Engineering, 2021,32(6): 215-221. (in Chinese)
[14] 陈策,邱元霖,韩佳,等. 解放闸灌域裸土期土壤盐分拟合模型研究[J]. 节水灌溉,2019(10):103-107.
CHEN Ce, QIU Yuanlin, HAN Jia, et al. Study on fitting model of soil salt in bare soil period of Jiefangzha Irrigation Area [J]. Water Saving Irrigation, 2019(10):103-107. (in Chinese)
[15] 史海滨,杨树青,李瑞平,等. 内蒙古河套灌区水盐运动与盐渍化防治研究展望[J]. 灌溉排水学报, 2020, 39(8): 1-17.
SHI Haibin, YANG Shuqing, LI Ruiping, et al. Soil water and salt movement and soil salinization control in Hetao Irrigation District: current state and future prospect[J]. Journal of Irrigation and Drainage, 2020, 39(8): 1-17. (in Chinese)
[16] 曹雷,丁建丽,玉米提·哈力克,等. 基于国产高分一号卫星数据的区域土壤盐渍化信息提取与建模[J]. 土壤学报,2016,53(6):1399-1409.
CAO Lei, DING Jianli, UMUT Halik, et al. Extraction and modeling of regional soil salinization based on data from GF-1 satellite[J]. Acta Pedologica Sinica, 2016,53(6): 1399-1409. (in Chinese)
[17] 姚一飞,王爽,张珺锐,等. 基于 GF-1 卫星遥感的河套灌区土壤含水率反演模型研究[J]. 农业机械学报,2022,53(9): 239-251.
YAO Yifei, WANG Shuang, ZHANG Junrui, et al. Inversion model of soil moisture in Hetao Irrigation District based on GF-1 satellite remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 239-251. (in Chinese)
[18] 杨宁. 无人机多光谱遥感估算土壤含盐量模型研究[D]. 杨凌:西北农林科技大学,2021.
YANG Ning. Research on UAV multispectral remote sensing model for estimating soil salt content[D]. Yangling: Northwest A&F University, 2021. (in Chinese)

[19] 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.

[20] BARET F, GUYOT G. Potentials and limits of vegetation indices for LAI and APAR assessment[J]. Remote Sensing of Environment, 1991, 35(2 - 3): 161 - 173.

[21] 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.

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

[23] 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.

[24] 孟小亮,粟骏龙,王帅,等. 一种高分辨率遥感影像多元线性回归建模方法[J]. 遥感信息, 2015(5): 37 - 41.
MENG Xiaoliang, SU Junlong, WANG Shuai, et al. An approach for modeling multiple linear regression of high-resolution remote sensing imagery[J]. Remote Sensing Information, 2015(5): 37 - 41. (in Chinese)

[25] 姜红,何辉. 基于支持向量机回归算法的土壤水分光学与微波遥感协同反演[J]. 地理与地理信息科学, 2017, 33(6): 30 - 36.
JIANG Hong, HE Hui. Soil moisture retrieval by synergizing optical and microwave remote sensing data based on support vector machine regression algorithm[J]. Geography and Geo-Information Science, 2017, 33(6): 30 - 36. (in Chinese)

[26] 张鲁子. 基于数据驱动和支持向量机的土壤水分含量反演研究[J]. 青岛大学学报(自然科学版), 2018, 31(4): 102 - 106.
ZHANG Luzi. Inversion of soil moisture content inversion based on data driven and support vector machine[J]. Journal of Qingdao University(Natural Science Edition), 2018, 31(4): 102 - 106. (in Chinese)

[27] 王枭轩,左小清,杨泽楠. 遥感影像重采样方法实现与应用研究[J]. 软件, 2019, 40(7): 42 - 46.
WANG Xiaoxuan, ZUO Xiaoqing, YANG Ze'nan. Research on realization and application of remote sensing image resampling [J]. Computer Engineering & Software, 2019, 40(7): 42 - 46. (in Chinese)

[28] 王新涛. 基于空-天遥感数据尺度转换的土壤盐渍化监测方法研究[D]. 杨凌:西北农林科技大学,2020.
WANG Xintao. Research on monitoring method of soil salinization based on scale conversion of space - air remote sensing data [D]. Yangling: Northwest A&F University, 2020. (in Chinese)

[29] 陈俊英,姚志华,张智韬,等. 大田葵花土壤含盐量无人机遥感反演研究[J]. 农业机械学报,2020,51(7):178 - 191.
CHEN Junying, YAO Zhihua, ZHANG Zhitao, et al. UAV remote sensing inversion of soil salinity in field of sunflower[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(7): 178 - 191. (in Chinese)

[30] 李友文,李春梅,郝璐. 我区农田、草地土壤墒情类型及其相对含水率等级指标的确定[J]. 内蒙古气象,1999(4):24 - 28.
LI Youwen, LI Chunmei, HAO Lu. Determination of soil moisture type and its relative water content grade index of farmland and grassland in our region[J]. Inner Mongolia Meteorological, 1999(4): 24 - 28. (in Chinese)

[31] 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 sunflower in saline soil[J]. Transactions of the CSAE, 2006,22(8): 44 - 49. (in Chinese)

[32] 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)

[33] 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)

[34] 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 retrival based on multi-source RS data in the Bailong Basin[D]. Lanzhou: Lanzhou University, 2014. (in Chinese)

[35] 张智韬,韩佳,王新涛,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, WANG Xintao, et al. Soil salinity inversion based on best subsets - quantile regression model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50 (10): 142 - 152. (in Chinese)

[36] 王国帅. 河套灌区不同地类间水盐运移规律及盐分重分布研究[D]. 呼和浩特:内蒙古农业大学,2021.
WANG Guoshuai. Study on water and salt transport and salt redistribution among different land types in Hetao Irrigation District [D]. Huhhot: Inner Mongolia Agricultural University, 2021. (in Chinese)

[37] 解雪峰,濮励杰,朱明,等. 土壤水盐运移模型研究进展及展望[J]. 地理科学,2016,36(10):1565 - 1572.
XIE Xuefeng, PU Lijie, ZHU Ming, et al. Evolution and prospects in modeling of water and salt transport in soils[J]. Scientia Geographica Sinica, 2016,36(10): 1565 - 1572. (in Chinese)

[38] 杜学军,闫彬伟,许可,等. 盐碱地水盐运移理论及模型研究进展[J]. 土壤通报,2021,52(3):713 - 721.
DU Xuejun, YAN Binwei, XU Ke, et al. Research progress on water-salt transport theories and models in saline-alkali soil [J]. Chinese Journal of Soil Science, 2021,52(3): 713 - 721. (in Chinese)