

DOI:10.3876/j.issn.1000-1980.2025.06.009

基于微波遥感和多模型集成的安徽省土壤湿度反演

孔月^{1,2,3}, 张珂^{1,2,3,4,5,6}, 申晓骥^{7,8}, 王晟^{5,9}, 王宇昊^{1,2,3}, 田鑫丽¹⁰, 何蒙¹⁰,
刘匡¹⁰, 向征¹⁰, 冯平¹¹

(1. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098; 2. 河海大学水文水资源学院, 江苏 南京 210098;
3. 河海大学长江保护与绿色发展研究院, 江苏 南京 210098; 4. 中国气象局水文气象重点开放实验室, 江苏 南京 210098;
5. 水利部水利大数据重点实验室, 江苏 南京 210098; 6. 水利部水循环与水动力系统重点实验室, 江苏 南京 210098;
7. 同济大学测绘与地理信息学院, 上海 200092; 8. 同济大学空间信息科学与可持续发展应用中心, 上海 200092;
9. 河海大学计算机与软件学院, 江苏 南京 211100; 10. 山东省水文中心, 山东 济南 250023;
11. 济南市水文中心, 山东 济南 250014)

摘要: 为准确反演安徽省土壤湿度, 提高机器学习模型的适应性和精度, 选用支持向量机回归、极端梯度提升、CatBoost、随机森林、自适应提升和 Stacking 模型(将前 5 种机器学习模型作为基模型, 线性回归作为元模型)反演安徽省土壤湿度, 并对 Stacking 模型的土壤湿度反演结果进行空间分布和时间序列分析。结果表明: 在输入相同遥感数据的情况下, Stacking 模型与单一模型相比具有更高的精度和鲁棒性, 反演得到的土壤湿度与实测数据之间的相关系数达到 0.72, 均方根误差为 $0.05\text{ m}^3/\text{m}^3$; 安徽省土壤湿度空间异质性较高, 北部地区较为干旱, 平均土壤湿度约为 $0.2\text{ m}^3/\text{m}^3$, 东部巢湖、长江地带较为湿润, 平均土壤湿度可以达到 $0.4\text{ m}^3/\text{m}^3$; 大别山区和皖南山区虽然海拔较高, 但土壤湿度还是高于淮北平原, 说明南北气候的差异可能影响土壤湿度; 整体看, 安徽省土壤湿度是由西北向东南递增的空间格局。

关键词: 土壤湿度; 集成学习; 遥感反演; 机器学习; 风云卫星; 安徽省

中图分类号: TP181 **文献标志码:** A **文章编号:** 1000-1980(2025)06-0075-07

Soil moisture inversion in Anhui Province based on microwave remote sensing and multi-model ensemble

KONG Yue^{1,2,3}, ZHANG Ke^{1,2,3,4,5,6}, SHEN Xiaoji^{7,8}, WANG Sheng^{5,9}, WANG Yuhao^{1,2,3}, TIAN Xinli¹⁰,
HE Meng¹⁰, LIU Kuang¹⁰, XIANG Zheng¹⁰, FENG Ping¹¹

(1. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China;
2. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China;
3. Yangtze Institute for Conservation and Development, Hohai University, Nanjing 210098, China;
4. China Meteorological Administration Hydro-Meteorology Key Laboratory, Hohai University, Nanjing 210098, China;
5. Key Laboratory of Water Big Data Technology of Ministry of Water Resources, Nanjing 210098, China;
6. Key Laboratory of Hydrologic-Cycle and Hydrodynamic-System of Ministry of Water Resources, Nanjing 210098, China;
7. College of Surveying and Geo-Informatics, Tongji University, Shanghai 200092, China;
8. Center for Spatial Information Science and Sustainable Development Application, Tongji University, Shanghai 200092, China;
9. College of Computer Science and Software Engineering, Hohai University, Nanjing 211100, China;
10. Shandong Province Hydrographic Centre, Jinan 250023, China;
11. Jinan Hydrographic Centre, Jinan 250014, China)

基金项目: 国家重点研发计划项目(2023YFC3006505); 中央高校基本科研业务费专项资金项目(B240203007); 国家自然科学基金项目(52309017); 江苏省自然科学基金项目(BK20230958)

作者简介: 孔月(2000—), 男, 硕士研究生, 主要从事生态水文研究。E-mail: 221301020001@hhu.edu.cn

通信作者: 申晓骥(1992—), 男, 研究员, 博士, 主要从事微波遥感、全球变化遥感研究。E-mail: xiaoji_shen@tongji.edu.cn

引用本文: 孔月, 张珂, 申晓骥, 等. 基于微波遥感和多模型集成的安徽省土壤湿度反演[J]. 河海大学学报(自然科学版), 2025, 53(6): 75-81.
KONG Yue, ZHANG Ke, SHEN Xiaoji, et al. Soil moisture inversion in Anhui Province based on microwave remote sensing and multi-model ensemble[J]. Journal of Hohai University(Natural Sciences), 2025, 53(6): 75-81.

Abstract: To accurately invert the soil moisture in Anhui Province and enhance the adaptability and accuracy of machine learning models, support vector regression, extreme gradient boosting, CatBoost, random forest, AdaBoost, and Stacking model (the first five machine learning models were selected as the base models, linear regression was used as the meta-model) were used to invert the soil moisture in Anhui Province. The spatial distribution and time series of soil moisture inversion results obtained from the Stacking model were analyzed. The results indicate that, with the same input remote sensing data, the Stacking model has higher accuracy and robustness compared to individual models. The correlation coefficient between the inverted soil moisture and the measured data reaches 0.72, and the root mean square error (RMSE) is 0.05 m³/m³. The spatial heterogeneity of soil moisture in Anhui Province is relatively high. The northern region is relatively dry, with an average soil moisture of around 0.2 m³/m³. The eastern areas of Chaohu Lake and the Yangtze River region are relatively humid, with an average soil moisture of up to 0.4 m³/m³. Although the Dabie Mountain area and the southern part of Anhui Province have higher altitudes, their soil moisture is still higher than that of the Huaibei Plain, indicating that the differences in climate between the north and the south may affect the magnitude of soil moisture. Overall, the spatial pattern of soil moisture in Anhui province is an increasing trend from the northwest to the southeast.

Key words: soil moisture; ensemble learning; remote sensing inversion; machine learning; Fengyun Satellite; Anhui Province

土壤湿度在农业、气候变化研究、水资源管理和生态环境保护等领域具有重要作用^[1-3],准确获取和监测土壤湿度是进行这些领域研究的重要基础。传统的土壤湿度测量方法主要包括现场采样和实验室分析,虽然结果较精确,但往往需要投入大量的人力和物力,其空间覆盖范围和时间连续性较差,难以满足大尺度和连续监测的需求^[4]。遥感技术通过对地表的连续观测,能够在大尺度上获取土壤湿度信息,并具有非接触、快速、范围大等优点^[5],可以克服传统方法的局限。被动微波卫星遥感获取的土壤湿度能有效提高土壤湿度估计的准确性,提升径流模拟精度^[6]。在被动微波卫星遥感土壤湿度产品中,SMAP 的反演效果最好^[7]。然而,用于土壤湿度反演的辐射传输模型复杂,反演精度会受土壤表面粗糙度和植被冠层的影响而降低^[8-10]。为了克服这些局限性,学者们将机器学习与土壤湿度反演进行结合:Zhang 等^[11]通过随机森林模型对全球地表土壤湿度进行了反演,展示了机器学习在土壤湿度估算中的潜力;王青青等^[12]建立了遗传算法优化的 BP 神经网络模型进行土壤湿度反演;刘娣等^[13]通过机器学习反演了多层土壤湿度。然而,单一的机器学习模型在处理复杂遥感数据时可能存在局限性,且大量的遥感数据需要得到训练和学习,为了进一步提高个体模型的预测精度,集成学习模型凭借其灵活性高、泛化能力强的优势,在算法比较和工业领域中越来越受欢迎^[14]。集成学习模型可用于准确预测多个土壤参数,包括土壤有机碳、总氮、盐度、pH 和质地^[15-19]。Stacking 模型是一种常用的集成学习模型,可以利用不同机器学习算法的特点,减少各个机器学习模型的方差,以提供更准确、稳定的预测^[20]。

本文选取了支持向量机回归 (SVR)、极端梯度提升 (XGBoost)、CatBoost、随机森林和自适应提升 (AdaBoost) 等模型,并将其与 Stacking 模型相结合,通过比较不同模型的精度,深入分析 Stacking 模型在空间分布和时间序列上的反演结果,验证 Stacking 模型在土壤湿度遥感反演中的适用性和稳定性,探索其在植被覆盖条件下的反演能力。

1 研究区概况与数据

1.1 研究区概况

安徽省地处中国东部,经纬度范围为 29°41'N ~ 34°38'N、114°54'E ~ 119°37'E。长江、淮河横贯全境,以淮河为界,北部属于暖温带半湿润季风气候,南部属于亚热带湿润季风气候。安徽省地形复杂多变,北部及中部地形平坦,多为平原,西部和南部地势较高,为山区,主要包括淮北平原、江淮丘陵、大别山区、沿江平原、皖南山区五大自然区(图 1)。

1.2 研究数据

1.2.1 土壤湿度实测数据

土壤湿度实测数据来自安徽省土壤湿度观测网,该观测网包括 38 个基本站和 44 个加密站(图 1)。站点主要使用 DZN2 型观测仪器,通过电容法获取土壤




图 1 安徽省概况及土壤湿度站点分布

Fig.1 Overview and soil moisture site distribution of Anhui Province

湿度。本文采用 0~10 cm 的土壤湿度日值作为研究对象,时间为 2012 年 1 月 1 日至 2016 年 8 月 19 日。

1.2.2 风云 3 号卫星亮度温度数据

风云 3 号卫星在天气预报、监测、全球环境变化和专业气象服务等任务上作出了巨大贡献,本文使用 FY3B 系列的亮度温度数据,空间分辨率为 0.25°,时间分辨率为 1 d,时间为 2012 年 1 月 1 日至 2016 年 8 月 19 日。选取了风云 3 号微波成像仪 5 个频率、2 种极化的 10 组亮度温度数据:10.65GHz-V、10.65GHz-H、18.7GHz-V、18.7GHz-H、23.8GHz-V、23.8GHz-H、36.5GHz-V、36.5GHz-H、89.0GHz-V、89.0GHz-H。

1.2.3 MODIS 遥感数据

MODIS MYD13C1 产品提供的归一化植被指数(NDVI)数据可以反映全球范围内植被生长情况。MODIS 的地表温度(LST)产品是重要的气象和环境监测工具,能提供全球几乎实时的地表温度信息。2 种数据均是基于 Aqua 卫星上的 MODIS 传感器收集的数据(时间为 2012 年 1 月 1 日至 2016 年 8 月 19 日,空间分辨率为 0.05°,时间分辨率为 16 d),采用线性插值方法处理为日数据,根据输入数据的一致性,将数据处理为空间分辨率 0.25°的日数据。

1.2.4 卫星降水数据

全球降水测量(GPM)旨在开发能够实现频繁且精确的全球降雨测量的下一代空间测量系统。同样选用观测时间为 2012 年 1 月 1 日至 2016 年 8 月 19 日的数据产品。

2 研究方法

2.1 机器学习模型

2.1.1 SVR

SVR 是一种回归算法,适应多种回归任务。SVR 最初用于解决分类问题,后来被扩展到回归领域。其基本原理是通过最小化预测误差来拟合数据,同时保持一个边界(间隔),以确保大多数数据点都位于该边界内^[21]。

2.1.2 XGBoost

XGBoost 是一种高效且灵活的梯度提升算法框架^[22]。XGBoost 加入了正则化项,在计算速度和内存使用方面得到了优化,是一种加法方案,通过不断迭代弱学习器逐步提升预测精度。

2.1.3 CatBoost

CatBoost 是一种基于对称决策树的高效算法^[23],能够直接在训练过程中处理分类特征,无需预处理。CatBoost 的另一大优势是基学习器使用的是完全对称二叉树,通过正则化和贝叶斯加权等技术,提高模型泛化能力。

2.1.4 随机森林

随机森林是由众多独立的决策树组成的算法,具有多功能性和易于使用的优点^[24]。随机森林通过对每棵树使用不同的样本和特征进行训练,从而产生不同的结果,这样能够显著降低过拟合的可能性。

2.1.5 AdaBoost

AdaBoost 属于集成方法中的提升类别,因其卓越的检测率和对过拟合的鲁棒性而备受认可。作为提升框架中一种有效且实用的算法,AdaBoost 通过在迭代过程中调整样本权重来训练弱分类器。训练完成后,错误率低的弱分类器权重增加,而错误率高的弱分类器权重减少。最终预测值通过对这些经过训练的弱分类器进行加权求和得到^[25]。

2.1.6 Stacking 模型

Stacking 模型是一种高效的集成学习模型,可将不同的基模型结合,不仅提升了预测精度,也增强了对复杂数据的泛化能力^[26]。该方法的核心是先使用多种机器学习模型分别训练不同的基模型,随后使用一个新的模型整合基模型的输出结果,生成最终的预测结果。本文基于 SVR、XGBoost、CatBoost、随机森林和 AdaBoost 这 5 种机器学习方法构建了 Stacking 模型,并采用 K 折交叉验证分割和训练数据。K 折交叉验证的步骤如下:①将训练数据集分为不重叠的 K 个相等子集,取 K-1 个子集作为训练数据集,剩下的 1 个子集作为验证数据集;②使用训练数据集训练模型,用训练后的模型处理验证数据集;③重复步骤①和②K 次,每次使用不同的子集作为测试集,训练结束后,采用一级回归器拟合整个数据集以获得最佳预测。

由于 SVR 可以处理非线性问题,XGBoost 和 CatBoost 可以适应高维复杂数据,随机森林抗噪性能优异,AdaBoost 灵活性高,因此本文选择 SVR、XGBoost、CatBoost、随机森林和 AdaBoost 作为基模型,以综合利用它们各自的优势。采用线性回归作为元模型,整合 5 种基模型的结果,既简洁稳定,避免了复杂模型过拟合,又能提升模型的整体预测精度和泛化能力。

2.1.7 数据预处理与模型建立

以亮度温度、NDVI、降水作为模型输入变量,实测土壤湿度数据作为目标变量,建立 Stacking 模型。75%的数据为训练集,25%的数据为测试集。将数据输入模型之前,采用 Min-Max 归一化将所有特征值缩放至 $[0, 1]$,统一尺度,避免特征差异影响模型训练。对时间序列中的少量缺失值采用线性插值法填补,无法填补的则删除,以确保数据完整性。为避免异常 NDVI 值和亮度温度值等对土壤湿度预测结果造成影响,预测过程中剔除了大型水体,所以部分栅格数据为空值。反演得到的土壤湿度空间分辨率为 0.25° ,预测期为 2015 年 8 月 20 日至 2016 年 8 月 19 日。

2.2 评价指标

采用皮尔逊相关系数(R)、均方误差(MSE)、均方根误差(RMSE)、平均绝对误差(MAE)及平均绝对百分比误差(MAPE)评估各模型土壤湿度的反演效果。

3 结果与分析

3.1 不同模型反演结果评价

机器学习模型的选取对预测精度具有重要影响,本文选取了多种机器学习模型,包括 Stacking 模型、SVR、CatBoost、随机森林、XGBoost 和 AdaBoost,评估了各模型反演安徽省土壤湿度的精度(表 1)。

表 1 不同机器学习模型的评价指标

Table 1 Evaluation metrics for different machine learning models

模型	R	$MSE/(m^3/m^3)^2$	$RMSE/(m^3/m^3)$	$MAE/(m^3/m^3)$	$MAPE/\%$
Stacking	0.718	0.003	0.051	0.042	13.6
SVR	0.698	0.003	0.058	0.045	15.1
CatBoost	0.555	0.004	0.065	0.054	17.7
随机森林	0.599	0.004	0.060	0.049	16.0
XGBoost	0.553	0.004	0.062	0.051	16.7
AdaBoost	0.434	0.005	0.067	0.057	18.9

SVR 和 Stacking 模型反演的土壤湿度与实测土壤湿度相关性较高, R 分别为 0.698 和 0.718,CatBoost、随机森林和 XGBoost 模型的反演结果较前两种稍差, R 分别为 0.555、0.599 和 0.553,AdaBoost 模型反演结果最差, R 为 0.434。Stacking 和 SVR 模型的 MSE、RMSE、MAE、MAPE 比其他 4 种模型小,说明了这 2 种模型得到的预测值与实测值之间的偏差较小、差异程度较小。

不同模型在各项评估指标上存在着一定的差异,Stacking 模型在多数指标上表现较好。其次是 SVR,各项评价指标略差于 Stacking 模型,但差距不大,较为接近。与 Stacking 和 SVR 模型相比,CatBoost、XGBoost 和随机森林模型在土壤湿度遥感反演中的表现相对较弱,AdaBoost 模型表现最差,AdaBoost 的 MAPE 相比于 Stacking 模型的高了 38.97%。综上,Stacking 和 SVR 模型在土壤湿度遥感反演中具有较好的预测性能,随机森林模型在某些指标上也有较为稳定的表现。Stacking 模型利用了其他 5 种模型作为基模型,通过集成这些基学习器的预测结果提高了整体的预测性能。

3.2 Stacking 模型反演结果

由图 2 可知,Stacking 模型可以较好地反演大部分区域的土壤湿度,少部分地区存在低估和高估的现象。安徽省北部和东部的部分地区,土壤湿度实测值与反演值的差值为 $0.01 \sim 0.03 m^3/m^3$,差值较小,差值产生的原因是植被覆盖影响了遥感反演效果^[27]。由图 2(c)(d)可知,在高植被覆盖区域(主要集中在南部和东南部),土壤湿度的反演误差相对较大,表明植被覆盖较高的地方会影响模型的反演能力,降低反演精度。

整体来看,安徽省土壤湿度存在着空间差异性,由西北向东南递增。北部地区较为干旱,平均湿度约为 $0.2 m^3/m^3$,东部土壤湿度的日均值大于西部。东部地形平坦为沿江平原,又有长江和巢湖,水资源丰富,土壤较为湿润,平均土壤湿度可达到 $0.4 m^3/m^3$ 。南部的皖南山区和沿江平原比北部淮北平原的土壤湿度稍

高,是南北气候区的差异造成的^[28]。虽然大别山区和皖南山区与沿江平原同纬度,但其土壤湿度均小于沿江平原,这是因为海拔对土壤湿度有一定的影响^[29]。




图 2 土壤湿度和 EVI 空间分布
Fig. 2 Spatial distribution of soil moisture and EVI

由图 3 可知,Stacking 模型反演的土壤湿度与实测值的整体相关系数达到 0.72,均方根误差为 0.05 m³/m³。在土壤湿度大于 0.3 m³/m³ 的部分,有略微的低估现象。实测值和反演值大部分在 0.2~0.4 m³/m³ 之间变化。

3.3 五大自然区时间序列对比

在五大自然区中,取不同区域内所有实测土壤湿度以及对反演土壤湿度的平均值代表区域的土壤湿度情况。淮北平原地区土壤湿度相较于其他 4 个自然区整体偏小,预测区内的平均值小于 0.300 m³/m³,其他地区在 0.300 m³/m³ 以上(表 2)。图 4 为安徽省五大自然区在预测期的时间序列对比,因为站点缺测或遥感数据缺失,所以在 2015 年 11 月和 12 月有段时间没有数据,但不影响总体趋势。五大自然区反演效果较好,Stacking 模型反演结果与实测数据保持了较高的一致性,相关系数从大到小的顺序为皖南山区(0.90)、江淮丘陵(0.87)、沿江平原(0.82)、大别山区(0.79)、淮北平原(0.73)。均方根误差在各区域的表现也相对一致,在 0.04~0.05 m³/m³ 之间。Stacking 模型在淮北平原地区 2015 年 9—11 月的反演值略高于实测值,在沿江平原和皖南山区 2016 年 4—7 月反演值略低于实测值。




图 3 Stacking 模型反演土壤湿度散点密度图
Fig. 3 Scatter density plot of inverted soil moisture by Stacking model

表 2 五大自然区预测期土壤湿度实测与反演的平均值

Table 2 Average values of observed and inverted soil moisture during prediction period in five major natural regions			
自然区	土壤湿度实测平均值/(m³/m³)		土壤湿度反演平均值/(m³/m³)
淮北平原	0.287		0.297
江淮丘陵	0.342		0.334
大别山区	0.328		0.313
沿江平原	0.357		0.337
皖南山区	0.347		0.326

由图 4 可知,在多次降水事件后,实测土壤湿度上升,而 Stacking 模型反演值未能及时跟随,表现出滞后性,表明 Stacking 模型对降水的敏感性不足。在 2016 年 5—7 月,降水量充足,Stacking 模型反演值存在低估现象,特别是在沿江平原和大别山区,模型未能捕捉到降水导致的土壤湿度剧增,说明其在湿润条件下表现欠佳。

从五大自然区的土壤湿度反演结果可以看出,Stacking 模型在各区域的预测效果存在一定差异,总体而言,沿江平原和皖南山区的土壤湿度预测结果较为精准,而淮北平原的预测效果相对较弱。这主要受多种因素影响:①气候和地形差异是影响模型精度的关键因素,皖南山区和大别山区地形起伏大,土壤湿度空间异质性强;②高植被覆盖区的植被冠层会干扰遥感信号,降低土壤湿度反演精度;③降水和气候条件的时空差异也影响模型预测效果。




图 4 土壤湿度反演值与实测值的时间序列
Fig. 4 Time series of inverted and observed soil moisture

4 结 论

- a. 安徽省土壤湿度为 $0.2 \sim 0.4 \text{ m}^3/\text{m}^3$, 模型反演得到的结果在土壤湿度较大的地区有轻微的低估现象。安徽省土壤湿度空间异质性较高, 北部地区较为干旱, 平均土壤湿度在 $0.2 \text{ m}^3/\text{m}^3$ 左右, 东部巢湖、长江地带较为湿润, 平均土壤湿度可以达到 $0.4 \text{ m}^3/\text{m}^3$ 。大别山区和皖南山区虽然海拔较高, 但土壤湿度还是高于淮北平原, 说明南北气候的差异可能影响到土壤湿度的大小。从空间分布看, 土壤湿度由西北向东南递增。
- b. Stacking 模型反演的土壤湿度数值波动比站点实测的数值波动小, 但两者的变化趋势相近, 表明 Stacking 模型能够较好地反映土壤湿度的波动行为。但是在降水量较丰富的时段, 模型的反演值在沿江平原和皖南山区有稍微低估, 说明模型对降水的敏感度不够强。

参考文献:

[1] ROBINSON D A, BINLEY A, CROOK N, et al. Advancing process-based watershed hydrological research using near-surface geophysics: a vision for, and review of, electrical and magnetic geophysical methods[J]. *Hydrological Processes*, 2008, 22(18): 3604-3635.

[2] 刘荣华, 张珂, 晁丽君, 等. 基于多源卫星观测的中国土壤湿度时空特征分析[J]. *水科学进展*, 2017, 28(4): 479-487. (LIU Ronghua, ZHANG Ke, CHAO Lijun, et al. Analysis of spatiotemporal characteristics of surface soil moisture across China based on multi-satellite observations[J]. *Advances in Water Science*, 2017, 28(4): 479-487. (in Chinese))

[3] SHEN Xiaoji, WALKER J P, YE Nan, et al. Impact of random and periodic surface roughness on P- and L-band radiometry[J]. *Remote Sensing of Environment*, 2022, 269: 112825.

[4] DENG Xiaodong, ZHU Luyao, WANG Hongquan, et al. Triple collocation analysis and in situ validation of the CYGNSS soil moisture product[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 1883-1899.

[5] SHEN Xiaoji, WALKER J P, YE Nan, et al. Soil moisture retrieval depth of P- and L-band radiometry: predictions and observations[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(8): 6814-6822.

[6] 何涯舟, 张珂, 晁丽君, 等. 基于多源遥感土壤湿度与模型数据同化的流域径流模拟[J]. *水资源保护*, 2023, 39(2): 145-151. (HE Yazhou, ZHANG Ke, CHAO Lijun, et al. Watershed runoff simulation based on multi-source remotely sensed soil moisture and data assimilation[J]. *Water Resources Protection*, 2023, 39(2): 145-151. (in Chinese))

[7] 何涯舟, 张珂, 晁丽君, 等. 基于多源卫星遥感产品的土壤湿度融合与降尺度研究[J]. *河海大学学报(自然科学版)*, 2022, 50(6): 40-46. (HE Yazhou, ZHANG Ke, CHAO Lijun, et al. Study on soil moisture merging and downscaling based on multi-source satellite remote sensing products[J]. *Journal of Hohai University (Natural Sciences)*, 2022, 50(6): 40-46. (in Chinese))

[8] SHEN Xiaoji, WALKER J P, YE Nan, et al. Evaluation of the tau-omega model over bare and wheat-covered flat and periodic soil surfaces at P- and L-band[J]. *Remote Sensing of Environment*, 2022, 273: 112960.

[9] SHEN Xiaoji, WALKER J P, YE Nan, et al. Evaluation of the tau-omega model over a dense corn canopy at P- and L-band[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 2504605.

[10] SHEN Xiaoji, FAN Lei, ZUO Tengting, et al. P-band radiometry for enhanced vegetation optical depth (VOD) and soil moisture retrieval in dense crop canopies[J]. *Remote Sensing of Environment*, 2024, 313: 114353.

[11] ZHANG Lijie, ZENG Yijian, ZHUANG Ruodan, et al. In situ observation-constrained global surface soil moisture using random forest model[J]. *Remote Sensing*, 2021, 13(23): 4893.

[12] 王青青, 张珂, 叶金印, 等. 安徽省土壤湿度时空变化规律分析及遥感反演[J]. *河海大学学报(自然科学版)*, 2019, 47(2): 114-118. (WANG Qingqing, ZHANG Ke, YE Jinyin, et al. Spatiotemporal analysis and remote sensing retrieval of soil moisture across Anhui Province, China[J]. *Journal of Hohai University (Natural Sciences)*, 2019, 47(2): 114-118. (in Chinese))

[13] 刘娣, 孙佳倩, 余钟波. 基于机器学习模型的多层土壤湿度反演[J]. *河海大学学报(自然科学版)*, 2024, 52(3): 7-14. (LIU Di, SUN Jiaqian, YU Zhongbo. Multi-layer soil moisture inversion based on machine learning models[J]. *Journal of Hohai University (Natural Sciences)*, 2024, 52(3): 7-14. (in Chinese))

[14] WANG Sinan, WU Yingjie, LI Ruiping, et al. Remote sensing-based retrieval of soil moisture content using stacking ensemble learning models[J]. *Land Degradation & Development*, 2023, 34(3): 911-925.

[15] HENGL T, DE JESUS J M, HEUVELINK G B M, et al. SoilGrids250m: global gridded soil information based on machine learning[J]. *PLoS One*, 2017, 12(2): e0169748.

[16] LI Hongyang, JIA Shengyao, LE Zichun. Quantitative analysis of soil total nitrogen using hyperspectral imaging technology with extreme learning machine[J]. *Sensors*, 2019, 19(20): 4355.

[17] SOTHE C, GONSAMO A, ARABIAN J, et al. Large scale mapping of soil organic carbon concentration with 3D machine learning and satellite observations[J]. *Geoderma*, 2022, 405: 115402.

[18] SWAIN S R, CHAKRABORTY P, PANIGRAHI N, et al. Estimation of soil texture using Sentinel-2 multispectral imaging data: an ensemble modeling approach[J]. *Soil and Tillage Research*, 2021, 213: 105134.

[19] VERMEULEN D, VAN NIEKERK A. Machine learning performance for predicting soil salinity using different combinations of geomorphometric covariates[J]. *Geoderma*, 2017, 299: 1-12.

[17] 李兆宇,贾金生,苏安双,等. 胶结土坝漫顶溃坝模型试验研究[J]. 河海大学学报(自然科学版),2022,50(5):98-104. (LI Zhaoyu,JIA Jinsheng,SU Anshuang,et al. Experimental study on overtopping and dam break model of cemented soil dam [J]. Journal of Hohai University(Natural Sciences),2022,50(5):98-104. (in Chinese))

[18] 易富,翟巍昆,杜常博,等. 尾矿库漫顶溃决动态演化及溃口展宽模型试验[J]. 水利水电科技进展,2023,43(3):34-41. (YI Fu,ZHAI Weikun,DU Changbo,et al. Dynamic evolution and breach spreading test for tailings pond overtopping failure[J]. Advances in Science and Technology of Water Resources,2023,43(3):34-41. (in Chinese))

[19] 翟巍昆,易富,杜常博,等. 尾矿坝漫顶溃决溃口纵向演化与侵蚀试验[J]. 水利水电科技进展,2023,43(5):45-52. (ZHAI Weikun,YI Fu,DU Changbo,et al. Longitudinal evolution of breach and erosion tests for tailings dam overtopping failure[J]. Advances in Science and Technology of Water Resources,2023,43(5):45-52. (in Chinese))

[20] ZHOU G G D,ZHOU Mingjun,SHRESTHA M S,et al. Experimental investigation on the longitudinal evolution of landslide dam breaching and outburst floods[J]. Geomorphology,2019,334:29-43.

[21] 俞振钊,彭辉,韩凯,等. 均质黏性土坝漫顶溃决过程试验研究[J]. 水电能源科学,2020,38(7):99-102. (YU Zhenzhao,PENG Hui,HAN Kai,et al. Experimental study on collapse process of homogeneous cohesive earth dam[J]. Water Resources and Power,2020,38(7):99-102. (in Chinese))

[22] 梁军,陈晓静. 纵向增强体土石坝漫顶溢流安全性能分析[J]. 河海大学学报(自然科学版),2019,47(3):238-242. (LIANG Jun,CHEN Xiaojing. Analysis on the overtopping safe operation performance of longitudinal reinforced rockfill dam[J]. Journal of Hohai University(Natural Sciences),2019,47(3):238-242. (in Chinese))

(收稿日期:2024-08-21 编辑:刘晓艳)

+++++
(上接第 81 页)

[20] 李占杰,陈基培,刘艳民,等. 土壤水分遥感反演研究进展[J]. 北京师范大学学报(自然科学版),2020,56(3):474-481. (LI Zhanjie,CHEN Jipei,LIU Yanmin,et al. Soil moisture retrieval from remote sensing[J]. Journal of Beijing Normal University (Natural Science),2020,56(3):474-481. (in Chinese))

[21] XU Lei,CHEN Nengcheng,ZHANG Xiang,et al. Improving the North American multi-model ensemble (NMME) precipitation forecasts at local areas using wavelet and machine learning[J]. Climate Dynamics,2019,53(1/2):601-615.

[22] 马春辉,侯媛媛,杨杰,等. 基于 RUN-XGBoost 算法的土石坝渗流预测模型[J]. 水利水电科技进展,2024,44(2):72-78. (MA Chunhui,HOU Yuanyuan,YANG Jie,et al. Seepage prediction model of earth-rockfill dams based on RUN-XGBoost algorithm[J]. Advances in Science and Technology of Water Resources,2024,44(2):72-78. (in Chinese))

[23] JABEUR S B,GHARIB C,MEFTEH-WALI S,et al. CatBoost model and artificial intelligence techniques for corporate failure prediction[J]. Technological Forecasting and Social Change,2021,166:120658.

[24] 张珂,牛杰帆,李曦,等. 洪水预报智能模型在中国半干旱半湿润区的应用对比[J]. 水资源保护,2021,37(1):28-35. (ZHANG Ke,NIU Jiefan,LI Xi,et al. Comparison of artificial intelligence flood forecasting models in China's semi-arid and semi-humid regions[J]. Water Resources Protection,2021,37(1):28-35. (in Chinese))

[25] XIAO Changjiang,CHEN Nengcheng,HU Chuli,et al. Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach[J]. Remote Sensing of Environment,2019,233:111358.

[26] 张宏鸣,陈丽君,刘雯,等. 基于 Stacking 集成学习的夏玉米覆盖度估测模型研究[J]. 农业机械学报,2021,52(7):195-202. (ZHANG Hongming,CHEN Lijun,LIU Wen,et al. Estimation of summer corn fractional vegetation coverage based on stacking ensemble learning[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(7):195-202. (in Chinese))

[27] 邓小东,王宏全. 土壤水分微波遥感反演算法及应用研究进展[J]. 浙江大学学报(农业与生命科学版),2022,48(3):289-302. (DENG Xiaodong,WANG Hongquan. Recent advances on algorithms and applications of soil moisture retrieval from microwave remote sensing[J]. Journal of Zhejiang University (Agriculture & Life Sciences),2022,48(3):289-302. (in Chinese))

[28] 李明星,马柱国. 中国气候干湿变化及气候带边界演变:以集成土壤湿度为指标[J]. 科学通报,2012,57(28/29):2740-2754. (LI Mingxing,MA Zhuguo. Soil moisture-based study of the variability of dry-wet climate and climate zones in China[J]. Chinese Science Bulletin,2012,57(28/29):2740-2754. (in Chinese))

[29] DU J,KIMBALL J S,JENCOS K,et al. Machine-learning based multi-layer soil moisture forecasts-an application case study of the Montana 2017 flash drought[J]. Water Resources Research,2024,60(10):e2023WR036973.

(收稿日期:2024-08-22 编辑:刘晓艳)