

面向地面观测稀缺区域的土壤湿度短期预测方法

王瑞祺¹, 陈伟涛², 陈浩³

1. 中国地质大学(武汉)地质探测与评估教育部重点实验室, 湖北武汉 430074

2. 中国地质大学(武汉)计算机学院, 湖北武汉 430074

3. 中国地质调查局自然资源航空物探遥感中心, 北京海淀, 100083

摘要: 高分辨率、高时效性的土壤湿度信息对农业、水文及生态领域的精细化管理至关重要。然而, 现有土壤湿度制图方法多依赖历史遥感影像反演, 或基于站点观测与低分辨率产品开展时间序列预测, 难以同步实现空间连续性与短期预测能力, 且在缺乏地面观测区域的应用受限。本研究提出一种集成“影像融合-偏差校正-空间降尺度-短期预测”的级联框架, 旨在不依赖研究区本地观测数据生成30 m分辨率、未来时相的多层土壤湿度分布图。首先, 在GEE平台融合Landsat与MODIS数据生成时空连续的高分辨率光谱指数; 其次, 利用GLDASv2.1产品对SMCI1.0土壤湿度产品数据进行全局偏差校正; 再结合地形、气象与土壤属性, 采用极端梯度提升模型将校正后SMCI1.0产品降尺度至30 m分辨率; 最后, 基于降尺度结果与滞后/未来气象变量, 构建XGBoost模型, 实现给定日期未来三天土壤湿度预测。基于闪电河流域地面观测网络(SDR-SMN)的验证表明: 偏差校正和降尺度过程均提升了原始SMCI1.0数据与地面观测的空间一致性; 预测模型在时间与空间独立交叉验证中表现稳健, 各层土壤湿度未来三天预测的 $R>0.6$ 。该框架能够为缺乏地面观测地区提供高分辨率土壤湿度短期预测方案。

关键词: 土壤湿度; 时空融合; 短期预测; 高分辨率制图; 空间降尺度

中图分类号: TP18;S152.71

收稿日期: 2026-2-2

Short-Term Forecast of Soil Moisture in Regions with Limited Ground Observations

Wang Ruizhen¹, Weitao Chen², Hao Chen³

1. Key Laboratory of Geological Survey and Evaluation of Ministry of Education, China University of Geoscience, Wuhan, China.

2. Faculty of Computer Science, China University of Geoscience, Wuhan, China.

3. China Aero Geophysical & Remote Sensing Center for Natural Resources, Beijing, China

Abstract: High-resolution and timely soil moisture information is essential for fine-scale management in agricultural, hydrological, and ecological applications. However, existing soil moisture mapping approaches mainly rely on historical remote sensing retrievals or time-series prediction based on in-situ observations and coarse-resolution products, making it difficult to simultaneously achieve spatial continuity and short-term forecasting capability. Moreover, their applicability is limited in regions lacking ground observations. This study proposed a cascading framework integrating image fusion, bias correction, spatial downscaling, and short-term prediction to generate multi-layer soil moisture maps at 30 m spatial resolution for near future without relying on local in-situ observations for model construction. First, Landsat-8 and MODIS data are fused on the Google Earth Engine platform to produce spatiotemporally continuous high-resolution spectral indices. Second, the SMCI1.0 soil moisture product is globally bias-corrected using the GLDASv2.1 product. Subsequently, the bias-corrected SMCI1.0 data are downscaled to 30 m resolution by incorporating terrain, meteorological, and soil properties through an Extreme Gradient Boosting (XGBoost) model. Finally, based on the downscaled soil moisture and lagged/forecast meteorological variables, XGBoost based prediction models are

基金项目: 中国地质调查局项目(DD20220301601, 20251960420), 地质探测与评估教育部重点实验室主任基金(GLAB2024ZR01)

第一作者: 王瑞祺(1993-), 男, 博士研究生, 主要从事智能地学信息处理理论与方法研究, E-mail: ruizhen.wang@cug.edu.cn

constructed to forecast soil moisture for up to three days ahead from a given date. Validation using the in situ observation network in the Shandian River Basin (SDR-SMN) demonstrates that both the bias correction and downscaling processes significantly improve the spatial consistency between the original SMCI1.0 product and ground measurements. The prediction model exhibits robust performance under temporally and spatially independent cross-validation, achieving correlation coefficients (R) greater than 0.6 for three-day-ahead soil moisture prediction across multiple soil layers. The proposed framework provides a practical solution for high-resolution short-term soil moisture prediction in regions with limited or no ground observations.

Keywords: soil moisture; spatio-temporal fusion; short-term forecast; high-resolution; downscaling

1 引言

土壤湿度指储存在土壤非饱和带中的水分含量，是全球气候观测系统（Global Climate Observing System）中的重要气候指标，对理解极端气候事件、水循环和能量平衡具有重要作用(Bojinski et al., 2014)。传统土壤湿度测量方法耗时且劳动强度大，且仅能提供点位观测数据。近几十年来，陆面模式和数据同化技术不断发展，通过融合卫星与地面观测，已经能在大尺度上生成长期、多层的土壤湿度数据集，如欧洲中期天气预报中心（ECMWF）的第五代再分析数据（ERA5）和全球陆地数据同化系统（GLDAS）。这些数据产品在干旱监测(Wu et al., 2025)、地质灾害监测(Distefano et al., 2023)以及越野通行能力评估(Frankenstone et al., 2015)等多个领域得到了广泛应用。

然而，实现高时空分辨率的多层土壤湿度监测仍然面临严峻挑战。现有同化数据集的空间分辨率通常为数十公里。尽管已有研究尝试将分辨率提升至 1 km(Li et al., 2022)，但在精细尺度应用中仍存在较大的不确定性(Sanchez et al., 2009)。高分辨率光学遥感数据（如 Landsat 系列影像）在辅助地形与土壤属性数据的支持下实现 30 m 分辨率的多层土壤湿度制图，但其重访周期长、易受云干扰，难以生成时间连续的产品。为此，融合高时空分辨率的遥感反射率数据成为一种有效解决方案。其中，增强型时空自适应反射率融合模型（ESTARFM）能够结合多时相 Landsat 影像与 MODIS 数据来预测 Landsat 尺度的光学反射率(Zhu et al., 2010)，并已成功应用于生成高分辨率、时间连续的土壤湿度图(Chen et al., 2025)。然而，该类方法仅限于历史时期的重建，无法满足实时或近期管理决策的需求。

短期土壤湿度预测能够提高土壤湿度分布信息的时效性，从而帮助决策者进行科学决策。预测需反映从观测日期到预测时段内土壤湿度的动态变化，这些变化主要受降水、气温和风速等气象要

素驱动(Ma et al., 2025)。这些要素控制着土壤水分的入渗与蒸散过程，并可通过天气预报数据获取。目前，土壤湿度预测通常基于地面观测(Togneri et al., 2022)，或被动微波遥感与再分析产品(Fang and Shen, 2020)建立模型。这些方法依赖于单个像元或站点的数据进行模型训练，难以直接生成空间连续的高分辨率预测图。例如 Chandra Joshi 等(2023)评估了一种基于像元的根区土壤湿度预测模型，但其空间分辨率仍然为千米级。Du 等(2024)利用原位观测与多源协变量建立了 30 m 分辨率的多层土壤湿度预测模型，但其依赖于月均 NDVI，可能无法捕捉短期植被动态，在环境快速变化时影响预测精度。

此外，现有高分辨率土壤湿度制图技术普遍高度依赖原位观测进行建模，使得相关技术在缺乏地面观测数据的区域难以开展(Ning et al., 2023)。

在上述背景下，本研究提出无需站点特定校准的多层土壤湿度短期预测与高分辨率制图框架，能够利用现有粗分辨率土壤湿度产品直接生成高分辨率预测结果。具体目标包括：(1) 利用影像融合方法提升高分辨率遥感数据的时间连续性；(2) 通过整合多源同化土壤湿度数据，建立全局偏差校正策略；(3) 基于极端梯度提升（XGBoost）集成学习模型，将 1 km 多层土壤湿度数据降尺度至 30 m 分辨率；(4) 在选定区域内提取 30 m 像元样本，构建基于 XGBoost 的给定日期未来三天土壤湿度预测模型。

2 数据源与方法

2.1 研究区概况

研究区位于中国河北省与内蒙古自治区交界处的闪电河流域（图 1）。该区域平均海拔约 147 5 m，地形以平坦为主，属于温带大陆性季风气候，

年平均气温约为 2.5 °C。年降水量在 300 至 500 mm 之间，大部分降水集中在 7 月至 9 月(Zhao et al., 2020)。

研究区地表水主要由降水补给形成，并在河谷地区与地下水之间存在一定水力联系，地下水对河流径流具有一定补给作用(杨丽娜等, 2023)。地下水主要靠降水补给，上游潜水含水层主要分布在沟谷地区，地下水埋深约 10–30 m。下游潜水含水层主要分布在河谷，地下水埋深约 0.86–15.29 m，呈现河谷中心浅、两侧深的分布特征(索瑞厅等, 2022)。在地下水埋深较浅区域，地下水可能通过毛管作用对深层土壤湿度产生一定影响，而浅层土壤湿度则主要受降水入渗和蒸散过程控制。

研究区植被以浅根系植物为主，根系集中在 10–50 cm 的土层(黄德华和陈佐忠, 1986)。植物通过根系吸收该深度范围内的水分，从而对土壤湿度动态产生一定影响。50 cm 及以下土层受植被根系直接吸水作用影响较弱，其湿度变化更多受到降水入渗、土壤水分垂向迁移以及地下水补给等因素控制。




图 1 (a) 中国闪电河流域研究地点位置；(b) 2019 年气象站及土地覆盖分布图；(c) 遥感影像及土壤湿度站点分布图。

Figure 1. (a) Location of study site in Shandian River basin, China. (b) Distributions of meteorological stations and landcover for 2019 (Yang and Huang, 2021). (c) Remote Sensing image and distributions of soil moisture stations

2.2 数据来源

2.2.1 SDR-SMN 土壤湿度监测数据

本研究使用的多层土壤湿度观测数据来自于自 2018 年开始投入的闪电河流域土壤湿度观测网络 (SMN-SDR) (Zhao et al., 2020)。该网络由 34 个

地面土壤湿度观测站组成 (位置分布见图 1)，包括草地观测站 30 个，耕地观测站 2 个，林地观测站 2 个。各站点配备有安装在 5 个不同深度 (3 cm、5 cm、10 cm、20 cm 和 50 cm) 的 Decagon EM50 (5TM) 传感器，以 10 或 15 分钟的时间间隔记录土壤湿度。测得的原始土壤湿度数据可通过以下校准公式进行校准(Zhao et al., 2020)。

目前 SMN-SDR 的土壤湿度连续观测数据可用至 2020 年 12 月 31 日。针对土壤属性空间降尺度中的四个目标土层深度区间，本研究拟使用 2018 年 9 月 6 日至 2020 年 12 月 31 日期间 SMN-SDR 测得的 10 cm、20 cm 和 50 cm 深度的土壤湿度数据分别用于表示全球土壤项目 “GlobalSoilProject” 规定的标准土层区间 5–15 cm, 15–30 cm, 30–60 cm 深度下的土壤湿度。校准后的数据通过计算平均值聚合成逐日数据。

2.2.2 SMCI 逐日土壤湿度产品

本研究使用的低分辨率土壤湿度产品数据来自于 SMCI 中国实地数据土壤湿度 (SMCI1.0) 的数据集，该数据集提供了中国 2000 年至 2022 年期间 1 km 分辨率的逐日多层次土壤湿度栅格产品 (Li et al., 2022)。该数据集基于中国气象局的全国 1700 多个土壤湿度站的数据以及 ERA-5 Land 气象与土壤湿度背景数据、MODIS 叶面积指数、土地覆盖类型、地形和土壤物理属性在内的一系列环境辅助变量，使用随机森林算法构建。该数据集的评估性能显示无偏均方根误差 (ubRMSE) 低于 0.052 cm³/cm³，相关系数 (R) 高于 0.866。

本研究在基于低空间分辨率降尺度产品的土壤湿度预测模型构建方案中使用 2018 年 9 月 6 日至 2020 年 12 月 31 日期间 SMCI 提供的 10 cm、20 cm 和 50 cm 深度的逐日土壤湿度栅格数据。该数据用于替代土壤湿度原位观测数据，以构建适用于没有土壤湿度地面观测数据的研究地点的预测模型。

2.2.3 GLDAS 逐日土壤湿度产品

用于对 SMCI 产品进行偏差校正的多层土壤湿度数据来自谷歌地球引擎 (GEE) 平台的 GLDASv2.1，该系统结合了卫星观测和地面观测数据，采用先进的陆面过程模拟与数据同化方法，能够提供关于陆地表面状况和能量交换的高精度估算 (Rodell et al., 2004)。已有研究表明，该数据集在中国大陆区域与地面观测数据相关系数较差，但在时间维度上整体上具有极小的系统性偏差 (Wu et al., 2021; Zheng et al., 2022)。本研究采用了与 SMCI 相同时间区间的空间分辨率为 0.25 °的土壤

湿度数据，提取 5–20 cm、20–40 cm 和 40–100 cm 三个土层的数据，以对应 SMCI 产品中的相应 10 cm、20 cm 和 50 cm 深度下的土壤湿度。

2.2.4 辅助变量

本研究所使用的辅助变量如表 1 所示。时间序列变量包括光谱反射率、气象因子和时间信息。高分辨率光谱反射率数据通过 GEE 平台获取自 Landsat 8 OLI 影像。用于数据融合的低分辨率光谱反射率数据来自 MODIS 数据。原始多波段反射率数据被转换为归一化植被指数 (NDVI) 和归一化短波红外差异土壤湿度指数 (NSDSI)，以捕获由植被主导的蒸散发信息和地表土壤湿度状况 (Tucker, 1979; Yue et al., 2019)。

高分辨率气象变量包括逐日气温、总降水量和风速，采用澳大利亚国立大学开发的 ANUSPLIN 模型进行插值获得。插值基于来自研究区周边 15 个气象站的连续观测记录 (见图 1b)，并使用高程、经度和纬度作为协变量。此外，还引入了年积日 (DOY) 变量，以帮助模型识别季节性变化和年度循环趋势 (Togneri et al., 2022; Ma et al., 2024)。

与流域水文相关的静态变量分为地形特征和土壤属性两类。地形变量包括高程、坡度和山体阴影，这些数据来自欧洲航天局提供的 30 m 分辨率 Copernicus 数字高程模型 (DEM)。土壤持水性与土壤结构具有关联性 (戴磊等, 2021)。相关的物理属性包括粘粒、砂粒、粉粒、碎石含量及土壤容重，数据来源于 250 m 分辨率的中国土壤信息网格数据库 (ChinaSoilInfoGrids) (Liu and Zhang, 2021)，并通过样条插值与成分数据分析方法相结合，将其插值至 30 m 分辨率 (Aitchison, 1982)。此外，土壤水力学特性残留水含量 (θ_r)、饱和水含量 (θ_s)、饱和导水率 (K_{sat}) 通过 Rosetta3 软件包估算。该软件利用预训练的神经网络模型，根据上述土壤物理属性预测 van Genuchten 方程中的水力参数 (Zhang and Schaap, 2017)。

表 1 研究所需变量的基本信息

Table 1. Ancillary variables used in this study

类	输入变量	空间分辨率	时间分辨
---	------	-------	------

型			率
时 间 序 列 变 量	MODIS NDVI	500 m	每日
	MODIS NSDSI	500 m	每日
	Landsat-8 NDVI	30 m	16 日
	Landsat-8 NSDSI	30 m	16 日
	温度	30 m	每日
	降雨量	30 m	每日
	风速	30 m	每日
静 态 变 量	年积日	30 m	每日
	高程	30 m	静态
	坡度	30 m	静态
	山体阴影	30 m	静态
	粘土含量	250 m	静态
	粉土含量	250 m	静态
	砂土含量	250 m	静态
	土壤容重	250 m	静态
	砾石含量	250 m	静态
	残余含水量	250 m	静态
	饱和含水量	250 m	静态
	饱和导水率	250 m	静态

2.3 技术方法

论文提出的土壤湿度短期预测与精细化制图该方法遵循“降尺度-预测”一体化框架 (图 2)。首先利用 GEE 图像融合算法，结合 Landsat 与 MODIS 遥感数据，生成具有时空连续性的光谱指数图像数据。其次，以 GLDAS v2.1 数据作为参考，对 1 km 分辨率的 SMCI 土壤湿度数据进行全局偏差校正。再通过 XGBoost 算法对多层土壤湿度数据进行空间降尺度，生成 30 m 空间分辨率的土壤湿度产品。最后，在不包括土壤湿度监测站点及周边像元的像元区域中，抽取部分像元位置的 30 m 时序土壤湿度与预测变量数据构建可迭代更新的 XGBoost 短期土壤湿度预测模型，并生成特定时期未来三日的土壤湿度短期预测空间分布，基于像元土壤湿度值和地面观测土壤湿度值对模型进行精度评估。




图2 土壤湿度短期预测与制图方法技术路线

Figure 2. Flowchart of the proposed framework.

2.3.1 GEE 图像融合

时空融合算法在高分辨率土壤湿度预测中的有效性已获验证，能够捕捉遥感反射率的日尺度变化，有助于更精细的模拟区域土壤湿度的短期动态。其中，增强时空自适应反射率融合模型（ESTARFM）在具有景观时空变化的地区表现稳定，并已被用于生成时空连续的土壤湿度。研究拟使用 GEE 图像融合算法实现 Landsat 和 MODIS 影像的融合并生成高时空分辨率的光谱反射率图像 (Nietupski et al., 2021)。该算法是 ESTARFM 算法的改进版本，可以在 GEE 云计算平台上运行，通过 Google 云盘直接下载融合后的时空连续的高分辨率图像到本地磁盘用于模型构建。算法具体描述见相关资料(Nietupski et al., 2021)。

本研究使用 2018 年 4 月 15 日至 2021 年 3 月 6 日期间的 Landsat-8 和 MODIS 数据生成时空连续的高分辨率 NDVI 和 NSDSI，完全覆盖实地土壤湿度地面观测数据的可用日期。为兼顾数据的可靠性与像元覆盖率最大化，采用了级联融合策略。首先根据先前研究的设定选取云量小于 5% 的 Landsat 图像用于 GEE 图像融合，以获取完整时序数据(Nietupski et al., 2021)，随后在地表覆盖快速变化或清晰 Landsat 图像间隔时间较长、融合效果不佳的时期，进一步引入云量在 5%–20% 之间的图像进行补充更新。用于融合和评估的日期如图所示（错误!未找到引用源。）。总共使用了 23 对 Landsat-8 和 MODIS 影像进行 GEE 图像融合过程，并在实地土壤湿度观测期间获得了 8 个独立日期的评估 Landsat-8 图像。此外，除了具有

影像对的日期外，还包括此期间的所有连续 MODIS 数据用于预测。对于这些图像，算法计算了冰雪指数以掩膜被雪覆盖像素，并进行空间配准以提高其与 Landsat-8 影像的地理位置一致性。




图3 GEE 图像融合过程和评估的 Landsat-8 图像拍摄日期

Figure 3. The dates of Landsat-8 images involved in data fusion process and evaluation.

2.3.2 基于 GLDAS 数据的偏差校正

SMCII.0 依据 ERA-5 Land 再分析数据和全国 1600 多个地面土壤湿度观测站构建而成，而 ERA-5 Land 在中国全部地区均存在不同程度的逐日高估偏差，并在 SMCII.0 数据集构建过程中所占权重极大，因此该产品仍存在普遍的土壤湿度高估情况(Wu et al., 2021; Zheng et al., 2022)。

本研究旨在不借助研究区的本地数据，充分利用现有 GIS 产品和先验知识来实现偏差校正。研究采用在中国地区长时间序列意义下系统性偏差较小、但相关性较差的 GLDASv2.1 土壤湿度数据进行全局校正。GLDASv2.1 将土壤深度分为 0–5 cm, 5–20 cm, 20–40 cm, 40–100 cm。为了使两个数据集的土壤湿度数据在垂直分布上对应，本研究拟使用 5–20 cm 的 GLDASv2.1 数据校正 10 cm 的 SMCII.0 数据，20–40 cm 的 GLDASv2.1 数据校正 20 cm 的 SMCII.0 数据，40–100cm 的

GLDASv2.1 数据校正 50 cm 的 SMC11.0 数据。参考先前研究中基于栅格的偏差校正方法(Y.-R. Zhang et al., 2023), 本研究的偏差校正流程如下(图 4) :

首先将 1 km 分辨率的 SMC11.0 土壤湿度数据通过计算每个 0.25°像元中所有 1 km 像元的均值, 使其空间聚合生成与 GLDASv2.1 相同的 0.25°分辨率的数据。由于偏差表现为特定地区长时间序列的综合结果, 本研究将每个 0.25°像素的校正值定义为这两个数据集在同时间序列下均值之间的差值。

$$\theta_{\text{bias}}^{0.25^\circ} = \mu(\theta_{\text{SMC11.0}}^{0.25^\circ}) - \mu(\theta_{\text{GLDASv2.1}}^{0.25^\circ}) \quad (2)$$

其中 $\theta_{\text{bias}}^{0.25^\circ}$ 为 0.25°分辨率下某一像素的偏差值, $\mu(\theta_{\text{SMC11.0}}^{0.25^\circ})$ 和 $\mu(\theta_{\text{GLDASv2.1}}^{0.25^\circ})$ 分别为 SMC11.0 空间聚合土壤湿度数据和 GLDASv2.1 数据在该像素中时间序列上的平均值。再通过三次样条空间插值的方法, 将 0.25°分辨率的偏差插值为 1 km 分辨率, 并对 SMC11.0 数据进行校正。

$$\theta_{\text{bias}}^{1\text{km}} = \text{Spline}(\theta_{\text{bias}}^{0.25^\circ}) \quad (3)$$

$$\theta_{\text{c}}^{1\text{km}} = \theta_{\text{SMC11.0}}^{1\text{km}} - \theta_{\text{bias}}^{1\text{km}} \quad (4)$$

其中 $\theta_{\text{bias}}^{1\text{km}}$ 为插值获得的 1 km 分辨率的偏差, $\theta_{\text{c}}^{1\text{km}}$ 为校正后的 SMC11.0 土壤湿度。




图 4 偏差校正流程

Figure 4. Flowchart of the bias correction.

由于 GLDASv2.1 属于再分析产品, 与地面观测数据之间存在一定的随机误差, 因此采用长期均值偏差校正方法, 能够对 SMC11.0 数据的系统性高估偏差进行调整, 同时保留其原有的时序变化特征。相较于逐日校正或其他可能改变源数据时序分布特征的方法, 该方法可避免因 GLDASv2.1 在单个日期存在误差而导致 SMC11.0 原有时序变化特征被削弱的问题。

2.3.3 SMC11.0 土壤湿度产品空间降尺度

在土壤湿度产品空间降尺度阶段, 30 m 空间分辨率的地形、气象和不同深度的土壤数据首先通过双线性降采样到 1 km 分辨率。由于 Landsat-MODIS 融合的 NDVI 和 NSDSI 数据受云量和低

相似度像元的影响, 图像在部分日期中存在较多缺失值而无法进行数学插值, 因此采用最邻近法进行重采样。重采样后环境辅助变量的作为 1 km 土壤湿度的预测变量。在降尺度环节, 气象变量仅采用目标时相及该时相过去 5 日的气象变量作为模型输入, 为模型引入土壤湿度的滞后效应, 提高降尺度模型的准确性。降尺度模型的目标变量为 2018 年 9 月 6 日至 2020 年 12 月 31 日期间校正后的 SMC11.0 数据集中 10 cm、20 cm 和 50 cm 深度的下 1 km 分辨率土壤湿度数据, 分别用于表征 5–15 cm、15–30 cm、30–60 cm 深度下的土壤湿度。每个土层深度单独作为目标变量用于回归模型构建:

$$\theta_{\text{SMC11.0}} = f(\text{NDVI}, \text{NSDSI}, \text{Relief}, \text{Meteorology}, \text{Soil}) \quad (5)$$

其中, $\theta_{\text{SMC11.0}}$ 是某一土层深度下的 SMC11.0 土壤湿度, Relief, Meteorology, Soil 分别是研究中使用的地形、气象和土壤辅助变量。在具体模型构建过程中, 选取目标深度以下或覆盖该深度的土壤属性作为输入变量, 以提供完整的土壤水文驱动信息, 例如在对 10 cm 深度土壤湿度进行降尺度时, 使用 0–5 cm 和 5–15 cm 土层的土壤属性数据 (错误!未找到引用源。)。在对预测因子与目标变量进行空间匹配后, 所有 NDVI 或 NSDSI 存在缺失值的 1 km 样本像元被排除在建模过程之外。

表 2 降尺度模型的层级输入

Table 2. Hierarchical model inputs of multiple soil layers for soil moisture downscaling.

深度	模型输入
10 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology (t-5, t-4, t-3, t-2, t-1, t), Relief, Soil (0-5, 5-15 cm)
20 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology (t-5, t-4, t-3, t-2, t-1, t), Relief, Soil (0-5, 5-15, 15-30 cm)
50 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology (t-5, t-4, t-3, t-2, t-1, t), Relief, Soil (0-5, 5-15, 15-30, 30-60 cm)

参考先前土壤湿度研究的针对遥感观测时相下的土壤湿度回归分析模型(Karthikeyan and Mishra, 2021; Zhang et al., 2022), 本研究继续采用极端梯度提升算法(Chen and Guestrin, 2016), 分别构建了 10 cm、20 cm 和 50 cm 三个土层深度的土壤湿度降尺度模型。最后将训练好的模型应用于 30 m 分辨率的辅助变量, 预测得到 30 m 分辨率的降尺度土壤湿度产品。

2.3.4 土壤湿度短期预测模型构建与制图

为满足短期预测的研究需求，本研究对时间序列的气象变量（气温、降水量和风速）及土壤湿度数据采用时间偏移方法进行了预处理，观测时相后连续 3 日的土壤湿度（ $t+1$ 、 $t+2$ 、 $t+3$ ）被设定为预测目标变量，以对接短时天气预报的应用场景以及当前 72 小时气象预报技术已具备较高可靠性和准确性的假设(Bi et al., 2023)。因此，短期模型引入了目标时相前 5 日（ $t-5$ 至 $t-1$ ）、当日（ t ）以及未来 3 日（ $t+1$ 至 $t+3$ ）的气象变量作为预测因子。

在模型构建过程中采用层级构建方式，仅使用截至预测日当天为止的气象信息，例如预测 $t+1$ 的土壤湿度时使用 t 和 $t+1$ 的气象数据，预测 $t+2$ 时使用 $t+1$ 和 $t+2$ 的气象数据，以此类推。在深层土壤属性方面，模型仅使用目标深度以下或覆盖目标深度的土壤层属性。例如，预测 10 cm 时则使用 0–5 cm 和 5–15 cm 层的属性，依此类推。这种层级输入方式保证了模型在数据使用上的前瞻一致性，模型的输入信息能涵盖土壤渗透、滞留和下渗等水文过程。

最后，光学遥感变量和年积日信息作为每一日（ t ）的输入变量被统一纳入所有层级模型，地形因子在所有预测时相和深度中保持一致。最终的模型输入变量如错误!未找到引用源。所示。

表 3 短期预测的层级模型输入

Table 3. Hierarchical model inputs of multiple soil layers for soil moisture forecast.

预测日期	深度	模型输入
第一天 ($t+1$)	10 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$), relief, soil (0–5, 5–15 cm)
	20 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$), relief, soil (0–5, 5–15, 15–30 cm)
	50 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$), relief, soil (0–5, 5–15, 15–30, 30–60 cm)
第二天 ($t+2$)	10 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$, $t+2$), relief, soil (0–5, 5–15 cm)
	20 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$, $t+2$), relief, soil (0–5, 5–15, 15–30 cm)

第三天 ($t+3$)	10 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$, $t+2$, $t+3$), relief, soil (0–5, 5–15 cm)
	20 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$, $t+2$, $t+3$), relief, soil (0–5, 5–15, 15–30 cm)
	50 cm	NDVI (t), NSDSI (t), DOY (t), Meteorology ($t-5$, $t-4$, $t-3$, $t-2$, $t-1$, t , $t+1$, $t+2$, $t+3$), relief, soil (0–5, 5–15, 15–30, 30–60 cm)

将各个土层深度的 30 m 空间分辨率降尺度土壤湿度数据与该分辨率下的预测变量结合构建土壤湿度预测模型。去除 NDVI 和 NSDSI 为缺失值的 30 m 样本像元后，基于剩余预测变量与目标变量的像元构建基于 XGBoost 算法的土壤湿度预测模型。由于将所有像元位置的数据全部输入模型将对计算资源提出极高要求(Fang and Shen, 2020)，本论文在建模过程中仅随机选取了 100,000 个像元位置（占有效像元位置总数的 0.2%）以兼顾计算资源的限制，选取时排除掉 SDR-SMN 站点及其周边占据的区域以确保基于地面观测数据的空间插值精度评估结果的可靠性。

2.3.5 评价指标

用于评估预测图像融合和土壤湿度性能的指标同样包括相关系数（R）、平均绝对误差（MAE）、均方根误差（RMSE）、无偏均方根误差（ubRMSE）和偏差（bias），计算公式如下：

$$R = \frac{\sum_{i=1}^N (y_{obs} - \bar{y}_{obs})(y_{pre} - \bar{y}_{pre})}{\sqrt{\sum_{i=1}^N (y_{obs} - \bar{y}_{obs})^2 (y_{pre} - \bar{y}_{pre})^2}} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{obs} - y_{pre}| \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{obs} - y_{pre})^2}{n}} \quad (8)$$

$$bias = \frac{1}{n} \sum_{i=1}^n (y_{pre} - y_{obs}) \quad (9)$$

$$ubRMSE = \sqrt{(RMSE)^2 - (bias)^2} \quad (10)$$

基于这些指标，本论文参考前人研究，采用了基于土壤湿度像元值的五折时间交叉验证与空间交叉验证策略(Chandra Joshi et al., 2023; Y. Zhang et al., 2023)。时间交叉验证用于评估模型在未见时间段内的预测能力，旨在降低时间噪声和

特定时段信息对模型训练的干扰，从而提高其在时间维度上的泛化性。而空间交叉验证则用于检验模型对空间异质性样本的泛化能力，通过在空间上独立的区域进行验证，评估其在未使用的像元空间位置预测效果。最后，论文还引入了地面实测土壤湿度数据进行空间独立验证，评估模型在实际应用层面的准确度。

3 结果与分析

3.1 GEE 遥感图像融合评估

基于 GEE 平台的图像融合技术成功生成了时空连续的 NDVI 与 NSDSI 数据，用于后续的空间降尺度分析与预测模型构建。初步的图像一致性评估表明（~~错误!未找到引用源。~~），该融合算法在多个指标上均表现良好。在 6 组评估日期中，融合生成的 NDVI 图像与参考数据的 R 值均超过 0.8，展现出显著的空间一致性，的 R 值介于 0.6–0.8 之间，仍保持较高的一致性。NSDSI 图像同样展现出相近的一致性，R 值在 6 组评估日期中超过 0.8，在其余两组中均大于 0.7。图对比了代表性日期 30 m 分辨率下原始数据与融合数据的空间分布及蜂窝密度图，直观展示融合效果。结果显示，融

合 NDVI 和 NSDSI 较完整预测出了真实图像的细节特征，其蜂窝密度图的斜率接近 1:1 基准线，表明融合数据在像元尺度上的高保真度。

表 4 GEE 遥感图像融合 NDVI 和 NSDSI 的评估
Table 4. Evaluation of fused NDVI and NSDSI

日期	NDVI			NSDSI		
	R	MAE	RMSE	R	MAE	RMSE
281, 2018	0.616	0.034	0.048	0.738	0.021	0.025
012, 2019	0.933	0.035	0.037	0.925	0.018	0.019
060, 2019	0.749	0.026	0.030	0.874	0.020	0.022
172, 2019	0.802	0.036	0.052	0.836	0.017	0.023
204, 2019	0.878	0.033	0.054	0.840	0.016	0.022
220, 2019	0.938	0.028	0.041	0.862	0.021	0.027
284, 2019	0.907	0.026	0.030	0.928	0.018	0.020
175, 2020	0.899	0.024	0.035	0.770	0.017	0.024




图 5 示例日期融合的 NDVI 与 NSDSI 空间分布及蜂窝密度图（2019 年 7 月 23 日）
Figure 5. Distribution and evaluation of fused NDVI and NSDSI on July 23rd, 2019.




图 6 融合的 NDVI 和 NSDSI 与不同深度的地面观测土壤湿度的相关性

Figure 6. Relationship of fused NDVI and NSDSI to in-situ soil moisture among depths.

该方法弥补了 Landsat 逐日影像的时间空缺，使得各土壤湿度监测站点在数百个采样日期能获得较为完整的研究期 30 m 分辨率预测变量遥感数据集。通过构建的数据集中对 15642 组样本的分析表明（图），通过图像融合获得的光谱指数与实测土壤湿度表现出一定的相关性，虽然融合光谱指数与不同深度土壤含水量的相关性随深度增加而减弱，但仍能在垂直剖面上提供稳定的解释力，对土壤湿度的空间降尺度与短期预测和制图具有重要贡献。相比于前人在土壤湿度预测建模中使用的逐月合成数据(Du et al., 2024)，逐日融合数据能够在时空维度上更精细地反映地表植被和水分参数的短期波动，为模型提供更有效的动态信息。

3.2 偏差校正评估

为了减小在构建 SMCI 数据集引入的显著湿度偏差的影响，论文采用了 GLDASv2.1 土壤水分数据集进行偏差校正。基于来自 34 个 SDR-SMN 站点、覆盖 853 个日期的土壤湿度地面观测数据，论文得到未校正 SMCI、经校正 SMCI 和 GLDAS v2.1 土壤湿度栅格数据的精度评估结果如表所示。可以明显观察到，在所选的三个土层深度上，校正后的 SMCI 产品的偏差和 RMSE 均有显著下降，说明校正方法有效改善了原始数据集中存在的系统性湿偏现象。就全部观测站点的平均评价结果而言，土壤湿度整体偏差减少了超过 $0.06 \text{ cm}^3/\text{cm}^3$ ，RMSE 减少了超过 $0.03 \text{ cm}^3/\text{cm}^3$ 。此外，修正后的 SMCI 数据集在 R 和 ubRMSE 方面与原始数据几乎保持一致，即相关性基本未受到改变，说明

该偏差校正策略在优化估计值的绝对误差的同时，较好地保留了土壤湿度时间序列的变异趋势与动态特征。综上所述，校正后的 SMCI 数据集产品相较于地面观测真实数据准确度有显著的整体提升。

表 5 原始的和经校正的 SMCI 和 GLDASv2.1 土壤湿度精度评价结果（基于 34 个站点的指标平均值）

Table 5. Evaluation metrics of original, corrected SMCI and GLDASv2.1 soil moisture (average of metrics for 34 stations)

土壤湿度数据集	评价指标	经校正的 SMCI		
		SMCI	GLDASv2.1	
10 cm	R	0.73	0.73	0.51
	Bias	0.077	0.006	0.005
	RMSE	0.104	0.062	0.071
	ubRMSE	0.04	0.04	0.051
20 cm	R	0.70	0.70	0.27
	Bias	0.083	0.022	0.025
	RMSE	0.111	0.074	0.082
	ubRMSE	0.038	0.038	0.048
50 cm	R	0.47	0.44	0.15
	Bias	0.074	0.003	0.01
	RMSE	0.102	0.069	0.078
	ubRMSE	0.038	0.038	0.052

为揭示不同站点在各土层的偏差校正响应特征，论文还基于 34 个站点的独立评估结果绘制了各评价指标的箱线图（错误!未找到引用源。）。结果表明，在各个土壤深度中，校正后的 SMCI 数据集产品在 R 和 ubRMSE 上的箱体形状与散点分布与原始数据集相似，而其偏差和 RMSE 的箱体

形状与散点分布则与 GLDASv2.1 数据集一致性更高, 反映了偏差校正方法能够将 SMCI 的数据特征有效向 GLDASv2.1 靠拢, 从而增强其代表性和可靠性。值得注意的是, 偏差校正方法在 30 个土壤湿度观测站点及三个土层深度上均带来了 bias 和 RMSE 的改善。然而, 箱线图中仍显示出少量异常站点, 校正后 SMCI 数据的 Bias 和 RMSE 指标反而较原始产品有所增加。根据对这些站点的原始观测结果进行回溯后发现, 这些站点在湿季期间经常出现极端土壤湿度值(Zheng et al., 2022)。土壤湿度观测值常在 $0.40 \text{ cm}^3/\text{cm}^3$ 以上, 部分日期超过 $0.50 \text{ cm}^3/\text{cm}^3$ 。这类情况通常出现在季节性水文导致的高饱和度土壤区域中。然而, SMCI 与 GLDASv2.1 两者均为栅格级遥感反演或模型同化产品, 空间分辨率较低, 难以精准捕捉这类微尺度下的高湿度极值区。这也导致偏差校正模型在这类站点上反而造成了高估误差, 从而出现负向效果。但尽管存在上述个别异常点, 整体而言, 偏差校正方法仍显著提升了 SMCI 产品在多数观测站点与土壤深度上的估计准确性。




图 7 通过 SDR-SMN 土壤湿度观测数据评估的原始 SMCI、校正 SMCI 和 GLDASv2.1 产品的 R、偏差、RMSE 和 ubRMSE 箱线图
Figure 7. Boxplots of R, bias, RMSE and ubRMSE of original SMCI, corrected SMCI and GLDASv2.1 products evaluated by SDR-SMN observation data.

3.3 土壤湿度空间降尺度评估

为验证所构建的 30 m 空间分辨率逐日多层土壤湿度降尺度产品的准确性, 论文对提出流程生成的土壤湿度降尺度图像开展精度评估, 评估采用了 SDR-SMN 的 34 个地面观测站点的实测数据, 结果首先以指标平均值的形式汇总于




图 9 利用草地 (L14) 和耕地 (M3) 两个站的数据, 对 1km、30m SMCI 和现场多层土壤湿度的时间变化进行比较。

Figure 9. Comparison of temporal variation of corrected 1 km, 30 m SMCI and in-situ multi-layer soil moisture by using data from two stations on grassland (L14) and farmland (M3).

中。总体来看, 降尺度处理在不同土层深度均引起了 R 值的提升, 尤其是在 50 cm 的深层土壤中, 平均 R 值提升幅度达到 0.17, 显示出较为显著的改进。此外, 各土层的 ubRMSE 值也均有轻微下降, 土壤湿度的随机误差在降尺度后有一定缓解。这些结果共同反映出降尺度过程在提供数据空间细节的同时, 验证了该方法在增强土壤湿度空间表达精度方面的有效性。

进一步的逐站点精度分析结果如图所示。从站点层面来看, 绝大多数验证站点的 R 和 ubRMSE 指标均表现出不同程度的改善, 尤以 50 cm 深度最为显著。在图中对比的箱线图显示, 降尺度后的与原始分辨率的土壤湿度数据在 R 值上的差值箱体 (红色) 整体位于 0 线以上, 而在 ubRMSE

E 上的差值箱线整体位于 0 线以下。这一趋势在所有土层中均较为明显,表明相较于低分辨率的原始数据,降尺度产品在绝大多数地点都提升了准确度。图则进一步展示了两个代表性站点(分别位于草地与耕地区域)上的时序对比结果。图中将地面观测值与原始 1 km 经校正的土壤湿度产品和 30 m 降尺度产品进行同步对比,分析其在时序动态变化中的拟合情况。尽管由于降尺度产品依赖于融合光学遥感数据的可用时相,30 m 产品的时间分布略少于 1 km 产品,但整体上,降尺度产品显著扩展了高分辨率土壤湿度图像的时效覆盖范围。在两个不同下垫面类型的站点上,30 m 降尺度结果在降雨输入或灌溉事件后对水分变化的响应更加灵敏,与地面观测的动态趋势吻合度更高。

表 1 1 km SMCI 校正土壤湿度和 30 m 空间降尺度的 SMCI 校正产品准确度评价 (34 个站点的平均值)

Table 6. Performance of 1 km corrected and 30 m downscaled corrected SMCI soil moisture (average of 34 stations)

土壤深度	评价指标	1 km 分辨率	30 m 分辨率
10 cm	R	0.66	0.69
	Bias	0.005	0.007
	RMSE	0.064	0.064
	ubRMSE	0.041	0.039
20 cm	R	0.62	0.66
	Bias	0.022	0.026
	RMSE	0.077	0.076
	ubRMSE	0.038	0.035
50 cm	R	0.35	0.52
	Bias	0.000	0.004
	RMSE	0.071	0.070
	ubRMSE	0.037	0.034




图 8 利用 SDR-SMN 观测数据评估校正的 1 km 和降尺度的 30 m SMCI 产品的 R、bias、RMSE、ubRMSE 的箱线图,以及它们之间的差异的箱线图。

Figure 8. Boxplots of R, bias, RMSE and ubRMSE of corrected 1 km and downscaled 30 m SMCI products evaluated by SDR-SMN observation data, as well as those of their differences.

图 10 展示了一个示例日期下, 1 km 分辨率的 SMCI 偏差校正土壤湿度产品与其对应的 30 m 分辨率降尺度结果。从图中可以看出, 降尺度后的多层土壤湿度分布在保留原始产品宏观空间格局的基础上显著增强了细节表达能力, 展现出更为丰富的空间变异性。这些细节特征主要源于高分辨率输入变量, 如光谱指数、地形、土壤属性等所提供的空间异质性信息, 使得土壤湿度在小尺度上的变化得以有效捕捉。更重要的是, 降尺度方法在一定程度上修复了 SMCI 原始数据中由于低分辨率 ERA5-Land 背景数据及传统土壤单元导致的不连续渐变的边界断裂和极端跳变现象。降尺度后的结果呈现出更为平滑且连续的空间分布, 尤其在土地利用类型交界处及坡地丘陵等复杂地形区域, 能够提供更合理、更连贯的土壤湿度估计。这一改进也与其他学者在 1 km 土壤湿度产品中观察到的问题相吻合(Brocce et al., 2024)。




图9 利用草地 (L14) 和耕地 (M3) 两个站的数据, 对 1km、30m SMC1 和现场多层土壤湿度的时间变化进行比较。

Figure 9. Comparison of temporal variation of corrected 1 km, 30 m SMC1 and in-situ multi-layer soil moisture by using data from two stations on grassland (L14) and farmland (M3).




图10 原始及降尺度多层土壤湿度空间分布示例 (2019年8月24日)

Figure 10. Original and downscaled multi-layer soil moisture on August 24th, 2019.

综上所述, 通过空间结构保留与细节增强的双重作用, 降尺度结果兼顾了大尺度格局与局地精细特征, 在构建高分辨率土壤湿度数据集过程

中提供了更具物理意义的空间信息表达方式, 能够为精细尺度下的土壤湿度短期预测模型构建提供更优质的间接数据。

3.4 土壤湿度短期预测与制图评估

表7展示了模型在多层土壤湿度短期预测任务中的整体性能表现。评估基于10万个随机选取的像元位置所构建的样本集, 采用时间独立和空间独立两种五折交叉验证策略开展, 统计指标为各验证折次所得结果的平均值, 以确保评估结果的稳健性与代表性。总体来看, 所构建的土壤湿度短期预测模型在不同情景和验证策略下均展现出较为稳定的预测性能。10 cm 与 20 cm 层的预测结果最为理想, 其 R 值在时间独立验证中均大于 0.6, 在空间独立验证中接近或大于 0.9, 表现出了显著优于 50 cm 深度的预测准确性。这一趋势在

不同的预报提前时间($t+1$ 至 $t+3$)下均保持一致,说明模型对中浅层土壤湿度具有良好的泛化性能和时空一致性。在 10 cm 与 20 cm 两个深度层中,10 cm 深度的整体预测精度略高于 20 cm,表明模型对地表附近湿度变化的捕捉能力更强。

值得注意的是,10–20 cm 层与 50 cm 层之间的相对预测精度在两种验证策略下呈现出相反的趋势,即深层土壤在时间独立验证准确度高于空间独立验证。这表明深层土壤湿度预测受制于样本空间分布特征及训练样本代表性,其泛化能力在空间迁移时有所下降。整体而言,随着土层深度的增加,模型在土壤湿度预测中的制图精度呈下降趋势。这一性能下降可能源于两个主要因素:一方面,根区较深层土壤湿度在降尺度过程中表现出更强的空间异质性,这种局部性差异很大程度上取决于点位的土壤水文特征,模型在缺乏站点先验信息的情况下难以准确还原其变化规律。另一方面,深层土壤湿度的时间稳定性更强,受气象

因子的直接驱动作用较弱,水分动态波动较弱、变化更缓慢,且具有更强的记忆效应,这导致模型在动态预测时更难捕捉其精细变化(Du et al., 2024; Ma et al., 2024)。

为了进一步直观展示模型预测的空间分布性能,图 11 展示了一个任选示例日期之后连续三天的预测土壤湿度图与真实(降尺度后)土壤湿度图的对比。图中的指标评估基于超过 3000 万个有效像元的单日数据完成,并剔除了用于模型训练的 10 万个像素点,确保了测试数据的空间独立性。结果显示,模型预测图与真实产品的空间分布形态显著一致,反映出模型对土壤湿度空间格局有较好的捕捉能力。但需要注意的是,预测图与真实图之间的一致性仍随着土层深度的增加而下降,这一空间制图精度下降趋势与表的交叉验证结果一致。这进一步印证了模型在深层土壤水分预测任务中的性能瓶颈,也强调了引入更多静态和动态变量以提升深层预测能力的必要性。

表 7 基于 100,000 个像元位置的像元值的土壤湿度预测交叉验证均值

Table 7. Pixel-based cross-validation for soil moisture forecasting with data from 100,000 pixel-locations.

预测日期	评价指标	10 cm		20 cm		50 cm	
		时间独立	空间独立	时间独立	空间独立	时间独立	空间独立
Day 1 ($t+1$)	R	0.66	0.94	0.65	0.89	0.68	0.61
	Bias	0.000	−0.001	−0.000	−0.002	−0.000	−0.002
	RMSE	0.024	0.011	0.025	0.016	0.020	0.022
	ubRMSE	0.022	0.011	0.023	0.015	0.019	0.021
Day 2 ($t+2$)	R	0.64	0.94	0.64	0.89	0.67	0.61
	Bias	0.000	−0.000	−0.000	−0.002	−0.000	−0.002
	RMSE	0.024	0.011	0.025	0.016	0.020	0.022
	ubRMSE	0.022	0.011	0.023	0.016	0.019	0.021
Day 3 ($t+3$)	R	0.60	0.94	0.61	0.89	0.65	0.61
	Bias	0.000	−0.001	−0.001	−0.002	−0.000	−0.002
	RMSE	0.025	0.011	0.026	0.016	0.021	0.022
	ubRMSE	0.023	0.011	0.024	0.016	0.019	0.021




图 11 第 275 天 (2020 年 10 月 1 日) 之后三天的 SMCi 降尺度产品真值和模型预测多层土壤湿度的空间分布, R 值和 RMSE 值通过使用除用于模型构建的 10 万个像素位置之外的像素计算。

Figure 11. Spatial pattern of original and forecasted multi-layer soil moisture for following three days of DOY 275 (October 1st, 2020). R and RMSE values were calculated using pixels apart from the 100,000 pixel-locations for model construction.

图 12 展示了基于 SDR-SMN 原位土壤湿度观测数据的补充评估结果, 旨在验证所构建框架在 SMCi 数据集上的最终适用性。在数据集构建阶段, 研究刻意排除了 SDR-SMN 观测网络及其周边区域内的像元, 以更客观地检验模型在未知区域的实际准确度, 即模型在训练过程中完全未接触过任何与评估站点相关的地理或观测信息。结果表明, 针对各个土层深度与目标时相的预测结果在大多数站点的 R 值与 ubRMSE 均处于合理范围: 10 cm 和 20 cm 土层深度中大多数观测站点的 R 值均在 0.4 到 0.7 之间, 50 cm 土层深度的 R 值略低于浅层土壤, 处于 0.3 到 0.7 之间。各个土层深

度与目标时相的 ubRMSE 值多小于 $0.05 \text{ cm}^3/\text{cm}^3$ 。这些统计结果表明所提出的预测框架在缺乏实测土壤湿度信息的区域中具备较强的适用性与推广潜力。然而需要指出的是, 误差中仍存在一定程度的系统性站点偏差, 这类偏差广泛存在于原始 SMCi 产品和降尺度后产品中 (见图), 是导致模型性能受限的重要因素之一。这些偏差可能源于站点周边土壤类型、地形条件、下垫面特征等静态信息的空间异质性未被构建原始数据集的模型有效识别或表达, 进而影响了预测结果的精度。




图 12 利用 SDR-SMN 土壤湿度原位观测数据评估未来三天多层土壤湿度预报的 R、bias、RMSE 和 ubRMSE 的箱线图。

Figure 12. Boxplots of R, bias, RMSE and ubRMSE of forecasted multi-layer soil moisture on three-days ahead evaluated by SDR-SMN observation data.

此外, 土壤湿度变化受到降水入渗、蒸散发、垂向迁移以及根系吸水等过程的共同作用, 而现有的模型输入对这些过程的表征能力有限, 在一定程度上限制了预测模型的表现。由于研究区部分河谷区域地下水埋深较浅, 深层土壤还受到地下水补给的影响(索瑞厅等, 2022), 而该过程未被模型考虑, 从而进一步限制了深层土壤湿度预测准确度。

综上所述, 尽管存在系统性偏差的影响, 但模型仍然取得了较为稳定的性能表现, 表明论文构建的土壤湿度短期预测精细化制图框架具备在缺乏地面观测支撑的区域开展广泛应用的潜力。

4 讨论

4.1 环境因子对土壤湿度短期预测的影响

为揭示数据驱动短期模型预测的驱动机制，本研究进一步通过特征重要性分析评估不同情景下环境变量对土壤湿度预测的贡献度，并对贡献差异进行比较分析。总的来看，不同深度变量重要性的存在显著差异，反映了土壤水分垂向运移过程从气象驱动向介质控制的转变机制。图 1 展示了土壤湿度预测模型中主要预测因子的贡献比例，以增强对土壤湿度变化的可解释性，并为揭示土壤湿度动态变化的驱动机制提供参考(Chen et al., 2025)。在 10 cm 和 20 cm 深度的六个预测模型中，年积日 (DOY) 和当日温度分别在五个和一个模型中被识别为最具影响力的因素。二者均能够反映季节性变化的周期性特征，而这种季节性变化通常对土壤湿度的时序波动起主导作用。DOY 和气温的显著性说明模型能够捕捉到气候季节信号与土壤水分变化之间的内在联系，这一结果与 Ma 等人的研究结论一致(Ma et al., 2024)。从特征重要性值的分布来看，DOY 和气温在深层土壤中的影响程度有一定减弱。从图中可以直观观察到，DOY 和温度在 10 cm 和 20 cm 深度的预测模型中贡献值能达到 0.15 以上，但在 50 cm 的三个模型中基本均低于 0.10。其中，DOY 的特征重要性逐渐下降至第四到第五位，并开始被静态土壤因子所超越。这主要是由于表层土壤对气象胁迫、土壤水分再分配过程以及根系吸水的响应通常更强，而深层土壤受外界扰动较小，水分变化相对稳定，其时间动态也因此减弱(Rosenbaum et al., 2012)。

光谱指数同样是重要的预测因子，这与前人研究结果一致(Chen et al., 2025; Li et al., 2024)。这一现象强调了利用数据融合方法生成连续且高分辨率光谱指数在实现本研究目标过程中的重要作用。从特征重要性分布可以看到，NSDSI 在九个预测模型中均有显著贡献，且在不同深度的模型中相对重要性较为稳定。由于短波红外波段波段对表层土壤水分的高敏感性(Yue et al., 2019)，使得 NSDSI 的贡献度在 10 cm 和 20 cm 深度中仅低于 DOY 或当日气温。在深层土壤中，模型则能通过 NSDSI 表征的表层湿度状态与土壤静态因子表征的下层土壤水分垂向传导和再分配能力推断深层

土壤湿度情况。而 NDVI 的整体贡献度相对较低可能是由于其主要反映植被生长状况，与土壤湿度之间的关系是间接的。此外，由于研究区整体以草地为主，整体受人为因素扰动较小，NDVI 变化的周期性显著而导致被 DOY 间接表征，导致其贡献度不足。最后，NDVI 的时空动态显著滞后于地表湿度变化，植被响应存在时间延迟，从而削弱了其对短期土壤湿度波动的刻画能力。因此，相较于更直接反映地表含水状态的 NSDSI，NDVI 在本研究的土壤湿度预测任务中表现出较低的特征重要性。

非季节性气象因子(风速、降雨量)在浅层土壤中也对土壤湿度有较大的影响力，但在深层土壤中影响较小，表明这些气象因子所驱动的短期水分输入与蒸散发过程主要作用于浅层土壤，垂向传递存在显著的时滞效应与衰减现象。随着深度增加，表层气象扰动在垂直方向的影响逐渐衰减，从而导致深层土壤湿度的时序变化对这些变量的敏感性降低。值得注意的是，降雨量在本研究中的特征贡献度并不显著。这种现象也在前人基于机器学习的土壤湿度反演研究中被多次观察到(Du et al., 2024; Karthikeyan and Mishra, 2021)，主要是由于在 1 km 分辨率及更精细的空间尺度上，土壤湿度的变化主要受特定空间位置的地表温度、地形和土壤质地等因素控制，而降雨量在基于较大尺度的低分辨率遥感土壤湿度产品建模时显著性相对较高(Karthikeyan and Mishra, 2021; Li et al., 2022)。例如 Ma 等的研究发现降雨量在基于地面观测数据建模时的重要性程度显著低于基于 ERA-5 Land 数十千米分辨率栅格土壤湿度数据建模(Ma et al., 2024)。

土壤属性例如砾石含量、土壤容重以及饱和导水率在深层预测中的贡献更为显著，尤其是在 50 cm 模型中，部分土壤理化参数的重要性接近或超过气象变量。这是由于表层动态过程对深层的影响较弱、土壤水分波动较小，使得模型预测更依赖于具有空间代表性的土壤信息，反映了深层土壤湿度主要受土壤介质特性与蓄水能力控制的特性。地形因子同样主要在深层土壤湿度预测中发挥重要作用，反映出深层土壤湿度受长期积水、地下水补给及地形控制的再分配格局影响更大。

综合来看，从表层到深层，主导因子从表征蒸散发、入渗的气象与光谱指数过渡到表征持水、渗漏的土壤物理属性和表征汇流的地形因子，完整刻画了降水入渗、根系吸水、深层渗漏的垂向水文过程。




图 1 不同预测情景下模型输入变量的重要性比例 (排名前 20 位)

Figure 13. Proportional importance of variables across various scenarios (Top 20).

4.2 不确定性分析

尽管本论文利用所提出的框架较好地实现了区域尺度 30 m 分辨率的多层土壤湿度预测模型构建与制图, 但基于多源再分析数据的统计降尺度方法在本质上仍存在各方面的不确定性(Ning et al., 2023)。这些不确定性来源可大体分为数据质量问题与框架方法局限性两类。首先, 在不依赖研究区本地地面观测数据的土壤湿度产品校正方案中, 融合 GLDASv2.1 数据的偏差校正是在较低的分辨率下实现的(Zhang et al., 2023)。因此即使进行了偏差校正, 全国尺度的 SMCI1.0 土壤湿度产品在精细尺度下的部分地区仍可能存在较大偏差。这些偏差可能源于算法假设、土层深度对应差异、以及输入数据误差的累积, 包括原始的 ERA5-Land 数据集在同化过程中的输入误差、构建 SMCI1.0 产品所用的机器学习模型误差, 以及遥感、地形、土壤辅助数据集准备环节中的不确定性(Li et al.,

2022)。尤其是基于 GEE 的影像融合算法本身的局限性和尺度转换过程,也可能进一步引入数据质量的不确定性。此外,本研究中使用的 72 小时未来时相的气象变量采用的是基于历史观测生成的产品,用于驱动结合气象预报的土壤湿度短期预测。因此,本研究是在理想气象条件下评估的模型性能。但在实际应用中,数值天气预报的预报误差可能导致土壤湿度预测精度和空间一致性下降。例如,预报降雨中心的空间位置偏差和强度误差可能导致特定地区水分输入量与实际不一致,影响土壤湿度预测结果。气温和风速的预报误差也可能通过影响预计蒸散发强度间接干扰土壤湿度的推算。因此,后续研究需结合实际气象预报数据进一步评估模型在实际场景下的性能。

其次, 本论文提出的框架包括偏差校正、降尺度和短期预测三个步骤, 而每一步都可能带来额外的不确定性。例如, 偏差校正过程可能继承 GLDASv2.1 数据集本身的不确定性。此外, 预测模型的结构本身也可能产生不确定性。树型机器

学习模型在外推能力上存在局限, 预测的值域范围依赖于训练数据的值域范围, 因此其性能往往具有较强的区域特异性。

4.3 框架适用性和可推广性

论文提出的空间降尺度与短期预测一体化框架可在缺乏土壤湿度地面观测网络的地区进行推广应用, 但具体的数据源选择与方法步骤需要结合当地条件进行适配。首先, 是否需要进行偏差校正应依据先验知识或本地调查评估目标区域的候选粗分辨率数据集适用性而定。例如, 前人已有研究表明 ERA-5 Land 土壤湿度产品在闪电河流域表现出整体的湿偏差, GLDASv2.1 数据在长时间序列意义下系统性偏差较小(Wu et al., 2021)。因此, 在这些研究区内, 通过 GLDASv2.1 数据对作为 ERA-5 Land 数据的再分析产品的 SMC11.0 数据进行整体性偏差校正具有充分的可行性。此外, 数据源的选择需要基于特定区域的数据可获取性。例如, 本论文使用的 SMC11.0 数据集在中国范围内提供了超过 20 年的多层逐日尺度 1 km 分辨率土壤湿度数据。在其他国家及地区, 可选择各类全球 1 km 土壤湿度产品如 GLASS SM 全球 1 km 土壤湿度数据集作为替代数据源(Zhang et al., 2023)。优先考虑使用 1 km 土壤湿度数据进行模型构建主要是为了尽可能的减小尺度效应的干扰。土壤湿度的变化在精细的空间尺度上主要受特定空间位置的植被覆盖、地形和土壤质地等因素控制, 而较大尺度的低分辨率遥感土壤湿度产品受气象因素控制的幅度相对较高(Karthikeyan and Mishra, 2021)。因此, 由于土壤湿度的实际控制因素在不同尺度下的差异性, 直接使用机器学习模型将数千米分辨率的土壤湿度数据如 SMAP、GLDASv2.1、ERA5-Land 等 9–36 km 的数据降尺度到 10–100 m 存在极大的尺度差异和不确定性挑战。相比之下, 从 1 km 到 30 m 的空间降尺度已在多项土壤水文相关变量研究验证具有可行性, 例如地表温度与蒸散发强度(Ke et al., 2017), 且 1 km 和 30 m 分辨率下的复杂环境土壤湿度建模研究在因子贡献度的分布上均表现为主要受特地区域环境特征控制(Karthikeyan and Mishra, 2021)。此外, 用于降尺度建模的 SMC11.0 产品本身为基于地面站点和通过统计建模方法构建的土壤湿度产品(Li et al., 2022)。因此, 在降尺度阶段采用机器学习方法本质上属于在同一统计建模框架内对已有模型输出结果进行再建模与空间重分配。本论文的结果进一步支持了该方法在提升土壤湿度空间细节与准确度方

面的有效性(Y. Zhang et al., 2023)。但对于希望利用更高更新频率但空间分辨率较低的数据源, 可考虑采用物理机制驱动的降尺度方法如 TOPSOIL 或 EMT+VS 模型(Fischer et al., 2025)来获得 30 m 的数据。

此外, 预测模型构建的适用性在很大程度上依赖计算资源。本研究在训练模型时, 采用了覆盖 805 个日期、约 10 万个像元位置的输入方式, 实时内存占用需求约 100GB, 但实际应用时, 采样像元数量可根据研究目标与可用计算资源进行灵活调整。由于土壤湿度的变化在精细的空间尺度上主要受特定空间位置的植被覆盖、地形和土壤质地等因素控制, 增加不同空间位置的样本数量有助于提高空间代表性, 使方法更接近基于土壤湿度全覆盖栅格产品经典土壤湿度预测框架(Fang and Shen, 2020), 并能更好地学习像元特征, 包括土壤、地形及空间异质性。但由于土壤湿度产品与地面观测结果仍存在一定差异, 增加不同空间位置的样本数量不一定直接提升与实测数据的对比精度, 但有助于更真实地重建原始土壤湿度产品的空间格局。

最后, 需要指出的是, 本研究选择的闪电河流域涵盖了草地、耕地、林地等多种下垫面, 土壤质地异质性较强, 为检验框架在复杂陆面条件下的有效性提供了一个有代表性的论证环境, 但在不同气候区的性能仍需基于本地数据体系系统评估。从方法论上来看, 框架基于可公开获取的数据源和标准化的数据处理流程, 这为其迁移到其他数据可获取的区域奠定了理论基础。然而, 不同气候区的水文过程主控因子可能存在差异, 模型输入变量和模型结构或需进行本地化调整。因此, 后续研究中可重点在全球不同气候与地貌类型区选取典型流域, 系统评估和校准该框架的实际预测能力。

5 结论

本研究通过集成图像融合、偏差校正、空间降尺度与机器学习预测模型, 构建了一个面向缺乏地面观测数据区域、不依赖地面数据参与模型构建的土壤湿度短期预测与高分辨率制图框架, 并验证该框架在典型区域的性能。研究采用事后观测气象数据作为理想输入条件以聚焦核心方法评估, 通过闪电河流域地面监测网络的验证, 取得主要结论如下:

在技术层面, 基于 GEE 平台的时空融合有效生成了连续的高分辨率 NDVI 与 NSDSI 序列, 为

模型提供了关键的动态输入。采用 GLDASv2.1 数据对 SMC1 产品实施的全局偏差校正, 显著降低了系统性高估误差。通过 XGBoost 模型融合高分辨率环境变量实现的降尺度处理, 在提升至 30 m 分辨率的同时, 增强了土壤湿度空间细节的表达能力与整体精度。

在预测验证层面, 基于随机抽取样本构建的未来三天预测模型, 在时间与空间独立交叉验证中均表现出稳健性能, 证实了该框架在缺乏原位观测的区域具备良好的实用潜力。

本方法为农业精准灌溉、区域水文监测及生态管理提供了可业务化推广的高时空分辨率土壤湿度制图方法。未来研究可在以下方向深入: (1) 未来气象变量需替换为实际的数值天气预报产品以评估预报误差带来的不确定性; (2) 在不同的气候和地理区域开展方法的长期验证与参数化研究; (3) 融合多源土壤湿度产品以优化数据基础; (4) 引入灌溉活动、地下水补给等局地过程机制, 以提升模型在深层土壤及极端水文条件下的预测能力; (5) 探索轻量化建模策略, 增强方法在不同计算资源条件下的适用性与泛化性。

参考文献

- Aitchison, J., 1982. The Statistical Analysis of Compositional Data. *J. R. Stat. Soc. Ser. B Methodol.* 44, 139–160. <https://doi.org/10.1111/j.2517-6161.1982.tb01195.x>
- Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., Tian, Q., 2023. Accurate medium-range global weather forecasting with 3D neural networks. *Nature* 619, 533–538. <https://doi.org/10.1038/s41586-023-06185-3>
- Bojinski, S., Verstraete, M., Peterson, T.C., Richter, C., Simmons, A., Zemp, M., 2014. The concept of essential climate variables in support of climate research, applications, and policy. *Bull. Am. Meteorol. Soc.* 95, 1431–1443.
- Brocca, L., Gaona, J., Bavera, D., Fioravanti, G., Puca, S., Ciabatta, L., Filippucci, P., Mosaffa, H., Esposito, G., Roberto, N., Dari, J., Vreugdenhil, M., Wagner, W., 2024. Exploring the actual spatial resolution of 1 km satellite soil moisture products. *Sci. Total Environ.* 945, 174087. <https://doi.org/10.1016/j.scitotenv.2024.174087>
- Chandra Joshi, R., Ryu, D., Lane, P.N.J., Sheridan, G.J., 2023. Seasonal forecast of soil moisture over Mediterranean-climate forest catchments using a machine learning approach. *J. Hydrol.* 619, 129307. <https://doi.org/10.1016/j.jhydrol.2023.129307>
- Chen, L., Hu, B., Sun, J., Xu, Y.J., Zhang, G., Ma, H., Ren, J., 2025. Using remote sensing and machine learning to generate 100-cm soil moisture at 30-m resolution for the black soil region of China: Implication for agricultural water management. *Agric. Water Manag.* 309, 109353. <https://doi.org/10.1016/j.agwat.2025.109353>
- Chen, T., Guestrin, C., 2016. Xgboost: A scalable tree boosting system, in: *Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*. pp. 785–794.
- Distefano, P., Peres, D.J., Piciullo, L., Palazzolo, N., Scandura, P., Cancelliere, A., 2023. Hydro-meteorological landslide triggering thresholds based on artificial neural networks using observed precipitation and ERA5-Land soil moisture. *Landslides* 20, 2725–2739.
- Du, J., Kimball, J.S., Jencso, K., Hoylman, Z., Brust, C., Ketchum, D., Xu, Y., Lu, H., Sheffield, J., 2024. Machine-Learning Based Multi-Layer Soil Moisture Forecasts—An Application Case Study of the Montana 2017 Flash Drought. *Water Resour. Res.* 60, e2023WR036973. <https://doi.org/10.1029/2023WR036973>
- Fang, K., Shen, C., 2020. Near-Real-Time Forecast of Satellite-Based Soil Moisture Using Long Short-Term Memory with an Adaptive Data Integration Kernel. *J. Hydrometeorol.* 21, 399–413. <https://doi.org/10.1175/JHM-D-19-0169.1>
- Fischer, S.C., Niemann, J.D., Scalia, J., Bullock, M.D., Proulx, H.E., Kim, B., Green, T.R., Grazaitis, P.J., 2025. Assessing the influence of model inputs on performance of the EMT + VS soil moisture downscaling model for a large foothills region in Northern Colorado. *J. Hydrol.* 650, 132397. <https://doi.org/10.1016/j.jhydrol.2024.132397>
- Frankenstein, S., Stevens, M., Scott, C., 2015. Ingestion of Simulated SMAP L3 Soil Moisture

- Data into Military Maneuver Planning. *J. Hydrometeorol.* 16, 427–440. <https://doi.org/10.1175/JHM-D-14-0032.1>
13. Karthikeyan, L., Mishra, A.K., 2021. Multi-layer high-resolution soil moisture estimation using machine learning over the United States. *Remote Sens. Environ.* 266, 112706. <https://doi.org/10.1016/j.rse.2021.112706>
 14. Ke, Y., Im, J., Park, S., Gong, H., 2017. Spatiotemporal downscaling approaches for monitoring 8-day 30 m actual evapotranspiration. *ISPRS J. Photogramm. Remote Sens.* 126, 79–93. <https://doi.org/10.1016/j.isprsjprs.2017.02.006>
 15. Li, Q., Shi, G., Shangguan, W., Nourani, V., Li, J., Li, L., Huang, F., Zhang, Y., Wang, C., Wang, D., Qiu, J., Lu, X., Dai, Y., 2022. A 1 km daily soil moisture dataset over China using in situ measurement and machine learning. *Earth Syst. Sci. Data* 14, 5267–5286. <https://doi.org/10.5194/essd-14-5267-2022>
 16. Li, Z., Yuan, Q., Su, X., 2024. High-spatial-resolution surface soil moisture retrieval using the Deep Forest model in the cloud environment over the Tibetan Plateau. *Geo-Spat. Inf. Sci.* 1–20. <https://doi.org/10.1080/10095020.2024.2307931>
 17. Liu, F., Zhang, G., 2021. Basic soil property dataset of high-resolution China Soil Information Grids (2010-2018). *Natl. Tibet. Plateau Data Cent.*
 18. Ma, H., Zeng, J., Zhang, X., Peng, J., Li, X., Fu, P., Cosh, M.H., Letu, H., Wang, S., Chen, N., Wigneron, J.-P., 2024. Surface soil moisture from combined active and passive microwave observations: Integrating ASCAT and SMAP observations based on machine learning approaches. *Remote Sens. Environ.* 308, 114197. <https://doi.org/10.1016/j.rse.2024.114197>
 19. Ma, L., Qi, S., Guo, S., 2025. Hydrologic Characteristics and Settlement Deformation of Backfilled Loess in Yan'an, China. *J. Earth Sci.* 36, 1198–1212. <https://doi.org/10.1007/s12583-024-1990-z>
 20. Nietupski, T.C., Kennedy, R.E., Temesgen, H., Kerns, B.K., 2021. Spatiotemporal image fusion in Google Earth Engine for annual estimates of land surface phenology in a heterogenous landscape. *Int. J. Appl. Earth Obs. Geoinformation* 99, 102323. <https://doi.org/10.1016/j.jag.2021.102323>
 21. Ning, J., Yao, Y., Tang, Q., Li, Y., Fisher, J.B., Zhang, Xiaotong, Jia, K., Xu, J., Shang, K., Yang, J., Yu, R., Liu, L., Zhang, Xueyi, Xie, Z., Fan, J., 2023. Soil moisture at 30 m from multiple satellite datasets fused by random forest. *J. Hydrol.* 625, 130010. <https://doi.org/10.1016/j.jhydrol.2023.130010>
 22. Rodell, M., Houser, P., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C.-J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., others, 2004. The global land data assimilation system. *Bull. Am. Meteorol. Soc.* 85, 381–394.
 23. Rosenbaum, U., Bogen, H.R., Herbst, M., Huisman, J.A., Peterson, T.J., Weuthen, A., Western, A.W., Vereecken, H., 2012. Seasonal and event dynamics of spatial soil moisture patterns at the small catchment scale. *Water Resour. Res.* 48, 2011WR011518. <https://doi.org/10.1029/2011WR011518>
 24. Sanchez, P.A., Ahamed, S., Carré, F., Hartemink, A.E., Hempel, J., Huising, J., Lagacherie, P., McBratney, A.B., McKenzie, N.J., Mendonça-Santos, M.D.L., Minasny, B., Montanarella, L., Okoth, P., Palm, C.A., Sachs, J.D., Shepherd, K.D., Vågen, T.-G., Vanlauwe, B., Walsh, M.G., Winowiecki, L.A., Zhang, G.-L., 2009. Digital Soil Map of the World. *Science* 325, 680–681. <https://doi.org/10.1126/science.1175084>
 25. Togneri, R., Felipe Dos Santos, D., Camponogara, G., Nagano, H., Custódio, G., Prati, R., Fernandes, S., Kamienski, C., 2022. Soil moisture forecast for smart irrigation: The primetime for machine learning. *Expert Syst. Appl.* 207, 117653. <https://doi.org/10.1016/j.eswa.2022.117653>
 26. Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8, 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
 27. Wu, Y., Zhong, Y., Liu, S., Xu, G., Xiao, C., Wu, X., Xie, B., Li, Z., Shum, C.K., 2025. Hydrogeodesy Facilitates the Accurate

- Assessment of Extreme Drought Events. *J. Earth Sci.* 36, 347–350. <https://doi.org/10.1007/s12583-024-0123-z>
28. Wu, Z., Feng, H., He, H., Zhou, J., Zhang, Y., 2021. Evaluation of Soil Moisture Climatology and Anomaly Components Derived From ERA5-Land and GLDAS-2.1 in China. *Water Resour. Manag.* 35, 629–643. <https://doi.org/10.1007/s11269-020-02743-w>
 29. Yue, J., Tian, J., Tian, Q., Xu, K., Xu, N., 2019. Development of soil moisture indices from differences in water absorption between shortwave-infrared bands. *ISPRS J. Photogramm. Remote Sens.* 154, 216–230. <https://doi.org/10.1016/j.isprsjprs.2019.06.012>
 30. Zhang, Y., Liang, S., Ma, H., He, T., Wang, Q., Li, B., Xu, J., Zhang, G., Liu, X., Xiong, C., 2023. Generation of global 1 km daily soil moisture product from 2000 to 2020 using ensemble learning. *Earth Syst. Sci. Data* 15, 2055–2079. <https://doi.org/10.5194/essd-15-2055-2023>
 31. Zhang, Y., Liang, S., Zhu, Z., Ma, H., He, T., 2022. Soil moisture content retrieval from Landsat 8 data using ensemble learning. *ISPRS J. Photogramm. Remote Sens.* 185, 32–47. <https://doi.org/10.1016/j.isprsjprs.2022.01.005>
 32. Zhang, Y., Schaap, M.G., 2017. Weighted recalibration of the Rosetta pedotransfer model with improved estimates of hydraulic parameter distributions and summary statistics (Rosetta3). *J. Hydrol.* 547, 39–53. <https://doi.org/10.1016/j.jhydrol.2017.01.004>
 33. Zhang, Y.-R., Shang, G.-F., Leng, P., Ma, C., Ma, J., Zhang, X., Li, Z.-L., 2023. Estimation of quasi-full spatial coverage soil moisture with fine resolution in China from the combined use of ERA5-Land reanalysis and TRIMS land surface temperature product. *Agric. Water Manag.* 275, 107990. <https://doi.org/10.1016/j.agwat.2022.107990>
 34. Zhao, T., Shi, J., Lv, L., Xu, H., Chen, D., Cui, Q., Jackson, T.J., Yan, G., Jia, L., Chen, L., Zhao, K., Zheng, X., Zhao, L., Zheng, C., Ji, D., Xiong, C., Wang, T., Li, R., Pan, J., Wen, J., Yu, C., Zheng, Y., Jiang, L., Chai, L., Lu, H., Yao, P., Ma, J., Lv, H., Wu, J., Zhao, W., Yang, N., Guo, P., Li, Y., Hu, L., Geng, D., Zhang, Z., 2020. Soil moisture experiment in the Luan River supporting new satellite mission opportunities. *Remote Sens. Environ.* 240, 111680. <https://doi.org/10.1016/j.rse.2020.111680>
 35. Zheng, J., Zhao, T., Lü, H., Shi, J., Cosh, M.H., Ji, D., Jiang, L., Cui, Q., Lu, H., Yang, K., Wigneron, J.-P., Li, X., Zhu, Y., Hu, L., Peng, Z., Zeng, Y., Wang, X., Kang, C.S., 2022. Assessment of 24 soil moisture datasets using a new in situ network in the Shandian River Basin of China. *Remote Sens. Environ.* 271, 112891. <https://doi.org/10.1016/j.rse.2022.112891>
 36. Zhu, X., Chen, J., Gao, F., Chen, X., Masek, J.G., 2010. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. *Remote Sens. Environ.* 114, 2610–2623. <https://doi.org/10.1016/j.rse.2010.05.032>
 37. 戴磊, 王贵玲, 何雨江, 2021. 基于分形理论研究土壤结构及其水分特征关系. *地球科学* 46.
 38. 杨丽娜, 贾德彬, 高瑞忠, 苏文旭, 卢方园, 郝玉胜, 2023. 闪电河流域“三水”氢氧同位素特征及水体转换分析. *环境科学* 44. <https://doi.org/10.13227/j.hjlx.202207230>
 39. 索瑞厅, 张绍兴, 姜德强, 李铤, 李旭峰, 2022. 多伦县地下水资源评价与可开采潜力分析. *湖南师范大学自然科学学报* 45.
 40. 黄德华, 陈佐忠, 1986. 内蒙古锡林郭勒沙地草场 49 种植物根系分布深度的初步观察. *中国草原*.