

顾及地形汇流效应的中国东北地区土壤湿度多产品协同降尺度研究

肖静, 李强子, 张源, 王红岩, 杜鑫, 许竞元, 董永

1. 中国科学院空天信息创新研究院 遥感卫星应用国家工程研究中心, 北京 100094;

2. 中国科学院大学, 北京 100049

摘要: 土壤湿度是陆地水文循环的重要变量, 对气候变化、农业生产和生态系统管理具有关键意义。然而, 现有的土壤湿度降尺度方法面临数据产品来源单一、协变量选择不全面等问题, 限制了其精度和应用范围。本研究以中国东北地区为案例, 提出了一种融合多尺度土壤湿度产品及地形汇流特征的降尺度框架, 并采用4种代表性机器学习方法, 构建了顾及地形汇流效应的多产品协同降尺度模型。研究表明, 在引入多源土壤湿度数据和地形汇流效应后, 模型决定系数 (R^2) 由0.839提升至0.849, 均方根误差RMSE (Root Mean Square Error) 由0.098降低至0.095, 偏差 (Bias) 从0.004减少至0.003。卫星土壤湿度产品为模型性能提升提供了互补信息, 而地形汇流特征通过描述水分输送机制, 提高了降尺度模型对土壤湿度空间分布的拟合能力。最终生成的高分辨率、逐日土壤湿度数据为精细尺度的土壤水分分析和应用提供了有力支持。

关键词: 土壤湿度降尺度, 中国东北地区, 多源数据, 机器学习, 深度学习, 地形汇流, 时空连续性, 土壤湿度产品

中图分类号: S152.71/TN957.52/P2

引用格式: 肖静, 李强子, 张源, 王红岩, 杜鑫, 许竞元, 董永. 2026. 顾及地形汇流效应的中国东北地区土壤湿度多产品协同降尺度研究. 遥感学报, 30(7): 2156–2177

Xiao J, Li Q Z, Zhang Y, Wang H Y, Du X, Xu J Y and Dong Y. 2026. Multiproduct collaborative downscaling of soil moisture in Northeast China considering terrain convergence effects. National Remote Sensing Bulletin, 30(7): 2156–2177 [DOI:10.11834/jrs.20264581]

1 引言

土壤湿度是地表系统中质量与能量循环的核心变量之一, 在陆地—大气能量交换、水文循环和生态系统功能中发挥着至关重要的作用 (Peng 等, 2017; 周壮 等, 2016)。作为干旱监测、碳循环建模和天气预报的基础数据, 土壤湿度在预测极端天气事件和评估生态系统健康方面具有重要价值 (Sabaghy 等, 2018; 曹永攀 等, 2011)。其广泛应用于农业、气象、水资源管理等领域, 能够有效优化作物水分管理、预测洪涝干旱风险, 并改进气候与碳循环模型。因此, 获取高质量、时空连续的土壤湿度数据具有广泛的应用意义

(Song 等, 2022; Senanayake 等, 2024)。传统的土壤湿度实测方法能够获得不同土层深度的土壤湿度数据, 具有较强的代表性和时间连续性, 且技术成熟、操作简便 (赵渭生和周月华, 1977; 邓英春和许永辉, 2007; Robock 等, 2000)。然而, 这种点尺度的监测方法难以有效反映大范围的土壤湿度空间变化 (Vinnikov 等, 1996; 卢建国 等, 2006)。

遥感技术作为一种面尺度土壤湿度监测的重要手段, 凭借大范围覆盖和高时间分辨率的数据获取能力, 在推动土壤湿度大范围监测方面发挥了重要作用 (Mohanty 等, 2017; 覃湘栋 等, 2021)。目前, 土壤湿度遥感监测主要依靠微波遥感; 光

收稿日期: 2024-12-27; 预印本: 2026-04-27

基金项目: 国家重点研发计划 (编号: 2021YFD1500103); 中国科学院战略性先导科技专项项目 (编号: XDA28070504); 高分辨率对地观测系统国家科技重大专项项目 (编号: 71-Y50G10-9001-22/23)

第一作者简介: 肖静, 研究方向为耕地灌排能力分析。E-mail: xiaojing221@mails.ucas.ac.cn

通信作者简介: 张源, 研究方向为农业灾害监测、物候模拟。E-mail: zhangyuan@aircas.ac.cn

学遥感则通过地表光谱特征间接获取土壤湿度，但其对地表条件十分敏感，尤其在云覆盖或复杂地形下，表现较差（Kogan, 1998; Song等, 2024）。微波遥感可分为主动微波遥感和被动微波遥感。主动微波遥感通过后向散射探测地表特性，但受地表粗糙度和植被覆盖影响较大，模型构建复杂且不确定性较高。相比之下，被动微波遥感利用地表辐射信号反演土壤湿度，受粗糙度和植被覆盖的影响较小，是土壤湿度监测的主要手段（Wang等, 2024）。被动微波遥感常用的波段包括C波段、X波段和L波段，基于这些波段的土壤湿度产品已广泛应用于实践（赵天杰, 2018; McNairn等, 2015）。土壤湿度面尺度监测的另一种主要手段是模式模拟。模式模拟将多源数据（如气象、地形和植被等的的数据）融合到数值或过程模型中，通过优化算法在模拟结果与观测数据间寻找最优解。代表性产品包括ERA5_Land、GLDAS（Global Land Data Assimilation System）和Noah-MP（Noah Multi-Parameterization）等，这些同化产品在提供时空连续土壤湿度数据方面表现优异，但空间分辨率较低，无法满足高分辨率区域应用的需求（Niu等, 2011; Rodell等, 2004; Muñoz-Sabater等, 2021）。尽管现有技术在土壤湿度监测中提供了良好的时空连续性，但空间分辨率不足的问题仍限制了其在精细化生态与水文过程研究、农业领域的精准管理及可持续资源管理等高精度需求领域的广泛应用。

在此背景下，学者们提出了通用三角法、数据同化法和机器学习方法3种土壤湿度降尺度方法。这些方法通过学习粗分辨率和精细尺度辅助变量之间的关系，获得时空连续的高分辨率土壤湿度数据产品（Merlin等, 2008）。通用三角法通过构建植被指数—地表温度三角形散点图，利用地表温度对土壤湿度的敏感性差异，提高土壤湿度数据产品的分辨率（吴盼等, 2016; Carlson等, 1994）。该方法操作简单，但易受云量、太阳辐射等因素影响，精度较低（Sabaghy等, 2018）。数据同化法通过结合不同波段的土壤湿度产品与模型或滤波处理，利用粗分辨率数据对高分辨率动态模型进行约束。此类方法虽然考虑了模型与卫星测量的不确定性，但同化过程的复杂性和模型参数选择的难度限制了其发展。这两种方法均无法描述土壤湿度与辅助变量之间的非线性关系，

因此机器学习方法应运而生。机器学习方法能够在数据分布不连续的情况下，通过数据驱动方式学习土壤湿度与多源协变量之间的复杂关系，整合不同来源的数据，处理动态且非线性的特征关联，从而生成高时空分辨率的土壤湿度降尺度数据（Wen等, 2021）。

目前，大多数降尺度方法依赖单一土壤湿度产品。然而，由于不同传感器、观测时段、波段及监测方法的差异，这些产品在精度上存在显著的时空异质性，这种误差会通过降尺度过程传递至精细尺度的土壤湿度产品，从而影响其准确性和可靠性。此外，现有降尺度模型通常考虑地表温度、植被指数、反照率、高程、坡度和土壤类型等协变量（Madhukumar等, 2022; 文凤平等, 2021; Xu等, 2021a）。这些协变量虽然提供了丰富的土壤湿度时空分布信息，但未全面考虑诸如地形汇流等关键因素，限制了降尺度模型的精度与可迁移性。针对机器学习方法中卫星土壤湿度数据来源单一、协变量选择不全面两大问题，本研究以中国东北地区为例，引入不同尺度和原理机制的土壤湿度卫星产品，并全面考虑包括地形汇流特征在内的气象数据、地表参数、植被指数、土壤质地数据等多维协变量。在此基础上，利用4种代表性机器学习方法，构建了顾及地形汇流效应的中国东北地区土壤湿度多产品协同降尺度模型，旨在生成更高精度（1 km）的精细尺度、时空连续的土壤湿度降尺度产品，以提升对生态与水文过程的动态解析能力，助力农业精细化管理。

2 研究区、数据和方法

本研究综合引入3种不同尺度和原理机制的土壤湿度产品，并顾及地形汇流、气象数据、直接地表参数、植被指数及土壤质地等多维协变量，通过基于4种机器学习方法的11种降尺度实验方案，开展精细尺度土壤湿度降尺度研究，明确了各协变量在降尺度过程中的作用与重要性，最终生成逐日的、具有时空完整性的千米尺度土壤湿度数据。总体研究技术路线如图1所示。本研究旨在评估不同机器学习模型，并结合多源土壤湿度数据及地形汇流相关变量的组合，以确定最佳模型和变量组合。具体研究内容如下：（1）比较4种机器学习模型在土壤湿度降尺度任务中的精度，

筛选出最优模型；(2) 设计两种实验方案，评估不同数据输入组合对模型性能的提升效果；(3) 将降尺度结果与实测土壤湿度数据进行对比，评估降尺度产品的适用性。

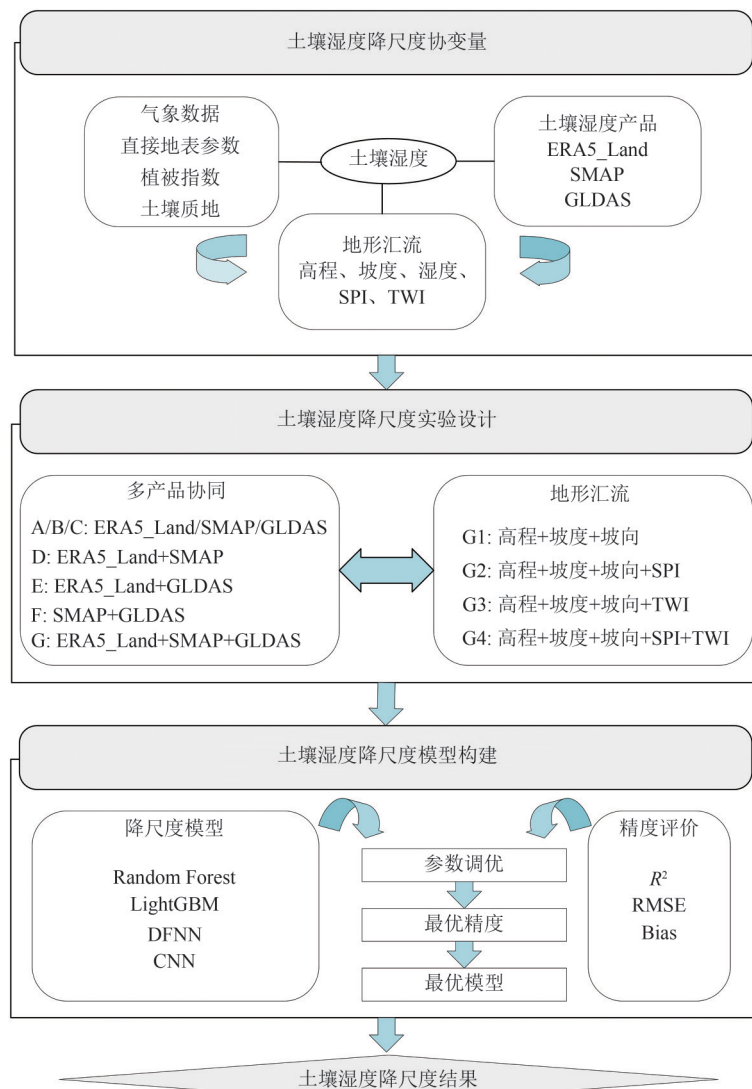



图1 技术路线(A—G、G1—G4为组合方案)

Fig. 1 Technology road (A—G, G1—G4 are combination schemes)

2.1 研究区概况

研究区(图2)位于中国东北部(38°N—54°N, 115°E—135°E), 涵盖黑龙江省、吉林省、辽宁省和内蒙古自治区的部分地区, 面积约125万km², 约占全国总面积的13%(杨奇峰等, 2022)。该地区属于半湿润大陆性气候, 降水量自东南(900 mm)向西北递减(400 mm), 降水量不均且夏季常发生高强度暴雨(Zhang等, 2010)。此外, 东北地区独特的漫川漫岗地形特征使得地形汇流因子对土壤湿度分布和变化具有重要影响, 因此在降尺度

过程中纳入地形因素, 可有效提升模型的适用性和区域可迁移性(Chen等, 2023)。该地区是中国最大的粮食生产基地和商品粮输出基地, 土壤湿度对作物生长及农业水资源管理具有直接影响(蔡壮, 2010)。然而, 现有土壤湿度数据的时空分辨率较低, 难以捕捉田块尺度上快速变化的土壤湿度分布特征, 限制了农业精准管理和资源优化利用的实施。因此, 开展土壤湿度降尺度研究, 能够在区域内生成具有更高时空分辨率的土壤湿度数据, 揭示其细尺度动态变化, 为精准农业和水资源优化配置提供科学支撑。



审图号:GS京(2026)0892号

图2 研究区

Fig. 2 Study area

2.2 协变量及数据源

本研究综合利用多种协变量，包括土壤湿度

产品、气象数据、直接地表参数、植被指数、地形汇流和土壤质地，开展土壤湿度降尺度研究（表1）。除3种土壤湿度产品外，考虑到归一化植被指数NDVI（Normalized Differential Vegetation Index）、增强型植被指数EVI（Enhanced Vegetation Index）等植被指数的空间分辨率限制，所有协变量的空间分辨率统一重采样为1 km，以确保在降尺度过程中数据的一致性和可靠性，从而提高降尺度结果的准确性。缺失值则通过线性插值进行初步填补。随后，利用萨维茨基—戈莱（Savitzky-Golay）滤波对数据序列进行平滑重建，以增强时间序列的连续性与准确性（Chen等，2004）。所有数据均采用阿尔伯斯（Albers）等面积圆锥投影进行空间统一，时间范围覆盖2019年1月1日至2023年12月31日。

表1 降尺度模型的多源数据来源

Table 1 Multi-source data sources for downscaling model

协变量		数据来源	空间分辨率	时间分辨率
土壤湿度产品	GLDAS	GLDAS-2.1	25 km	逐3 h
	SMAP	SPL4SMGP006	9 km	逐3 h
	ERA5_Land	ERA5_Land; Volumetric soil water layer 1	8 km	逐小时
气象数据	降水量	ERA5_Land; Total precipitation	8 km	逐小时
	气温	ERA5_Land; 2 m temperature	8 km	逐小时
直接地表参数	反照率	MCD43A3	500 m	逐日
	蒸散发、潜在蒸散发	MOD16A2	500 m	逐8 d
植被指数	NDWI	MOD09A1, MYD09A1	500 m	逐8 d
	NDVI, EVI	MOD13A2, MYD13A2	1 km	逐8 d
地形汇流	高程、坡度、坡向、SPI、TWI	STRM	30 m	—
土壤参数	砂土、粉砂土、黏土	中国科学院资源环境科学数据中心	1 km	—

注：SPI(Stream Power Index)为水流强度指数、TWI(Topographic Wetness Index)为地形湿度指数、NDWI(Normalized Difference Water Index)为归一化差异水体指数,ERA5_Land再分析数据产品原始分辨率为0.1°,根据纬度与投影坐标系关系变化,其空间分辨率在东北地区范围内约为8 km。

2.2.1 土壤湿度数据产品

本研究引入GLDAS、SMAP、ERA5_Land这3种不同物理机制的土壤湿度产品，利用其尺度和原理上的互补性，提升土壤湿度降尺度模型的精度。

GLDAS-2.1版本提供了0—10 cm地表土壤湿度数据（数据来源：https://disc.gsfc.nasa.gov/datasets/GLDAS_NOAH025_3H_2.1/summary?keywords=GLDAS [2024-12-27]）。该数据集通过数据同化的方法提供了全球范围内的连续气候和水文变量数据，能够在25 km的空间分辨率下模拟逐3 h、不同土壤

层次的水分动态（Zhang等，2021a）。本研究结合单层土壤厚度和土壤密度，将土壤湿度转换为体积土壤湿度后获得逐日数据。经中国东北地区的原位土壤湿度数据验证，其决定系数（ R^2 ）为0.384、均方根误差RMSE（Root Mean Square Error）为0.09、偏差（Bias）为0.05（Hong等，2024）。

SMAP卫星的Level-4（L4）级产品SPL4SMGP.007提供逐3 h的0—5 cm表层土壤湿度数据。本研究将其统一至日尺度（数据来源：<https://appears.earthdatacloud.nasa.gov/> [2024-12-27]）。SMAP数据凭借其全球覆盖、高时间分辨率和较高空间分

分辨率等优势成为土壤湿度监测的理想数据源。经中国东北地区的原位土壤湿度数据验证, 其 R^2 为0.261、RMSE为0.08、Bias为0.08 (Hong等, 2024)。该产品通过将卫星土壤亮度温度观测结果同化到Catchment陆面模型中, 生成空间分辨率为9 km的数据集 (Chen等, 2018; 王思超等, 2024)。

ERA5_Land数据集基于第五代再分析资料, 提供逐小时的0—7 cm表层土壤湿度数据, 并通过按日聚合处理生成逐日数据 (数据来源: <https://cds.climate.copernicus.eu/datasets> [2024-12-27])。ERA5_Land是由欧洲中期天气预报中心ECMWF (European Centre for Medium-Range Weather Forecasts) 开发的高分辨率全球数据同化系统, 它通过将卫星观测数据与数值天气预报模型相结合, 提供全球范围内精确的气象和土壤湿度信息 (王乙竹等, 2023; Muñoz-Sabater等, 2021)。经中国东北地区的原位土壤湿度数据验证, 其 R^2 为0.413、RMSE为0.12、Bias为0.105 (Hong等, 2024)。该数据集有效弥补了海洋、高原等偏远地区地面观测站点的不足, 是获取近地面气象分布和土壤状态的重要工具 (Zhang等, 2021c)。

2.2.2 地形汇流

土壤湿度降尺度模型的精度常受地形因素影响, 尤其是在忽视地形汇流效应的情况下。地形汇流是指地表水流动对土壤湿度分布的影响, 它直接决定了水分在不同区域的集聚与流失模式 (Ji等, 2017; Meng等, 2023)。土壤湿度的空间分布受降水量、蒸发及水分迁移等多因素共同作用, 其中地形在水分分布中扮演了关键角色, 特别是在丘陵和山地等复杂地形区域, 水分分布往往表现出显著的空间异质性 (Yang等, 2017)。东北地区具有典型的漫川漫岗地形, 水流在这些区域呈现出较强的汇流效应。尤其是在低洼的漫川与高起的漫岗之间, 地形特征决定了水分的集聚与流失模式, 从而使土壤湿度的空间分布呈现出显著差异。因此, 为提高降尺度模型的预测精度, 本研究引入了水流强度指数SPI (Stream Power Index)、地形湿度指数TWI (Topographic Wetness Index) 等地形汇流特征, 以更加准确地表征地形对水分分布的影响, 从而更好地模拟土壤湿度的空间变化规律。

高程数据来自航天飞机雷达地形测绘任务数字高程模型SRTM DEM (Shuttle Radar Topography Mission Digital Elevation Model) 数据集, 空间分辨率为30 m (数据来源: <https://www.resdc.cn> [2024-12-27])。坡度和坡向数据通过ArcGIS10.6中“坡度”和“坡向”分析功能生成。高程影响降水量的分布和气候条件, 而坡度和坡向则决定了水分的流动方向 (Wang等, 2022)。这些协变量能够有效反映土壤水分的空间异质性, 提高模型的适应性。

SPI和TWI通过综合计算汇流量与坡度信息获得。这两个指标均为描述区域地形对径流流向和水分蓄积影响的关键物理参数, 计算公式见式(1)和式(2) (Rodhe和Seibert, 1999)。两个指标值越高, 表明水分流向更集中, 径流的汇流效应越强 (Yang等, 2017)。通过引入这两个协变量, 本研究能够更有效地反映地形对水流的引导作用, 揭示土壤湿度在不同地形单元上的分布规律, 尤其是在坡度较大、降水量不均的地区, 从而更好地揭示土壤湿度的空间异质性。

$$SPI = SCA \times \tan(\text{Slope}) \quad (1)$$

$$TWI = \ln[SCA / \tan(\text{Slope})] \quad (2)$$

式中, Slope为坡度信息; SCA为单位面积的汇流量, 计算公式为

$$SCA = \text{Flow Accumulation} / \text{Cell Area} \quad (3)$$

式中, Flow Accumulation为流量累积值, Cell Area为栅格单元的实际面积。

2.2.3 气象数据

气温和降水量是影响土壤湿度变化的关键气象因子, 能够反映地表能量平衡和水分循环的过程, 可为降尺度模型提供重要的物理约束。

气温和降水量数据来源于ERA5_Land数据集, 包含逐小时的近地面(2 m高度)气温和降水量数据。为构建逐日尺度的数据集, 气温数据采用日均值计算, 降水量数据则进行日总量聚合处理。

2.2.4 直接地表参数

直接地表参数通常指描述地表物理特征和能量交换过程的变量, 它们直接影响地表热量和水分的传输过程。在众多直接地表参数中, 反照率反映了地表对太阳辐射的反射能力, 对土壤湿度的空间分布具有重要影响 (Mueller等, 2011); 蒸

散发和潜在蒸散发与土壤湿度密切相关，能够提供水分消耗的关键信息，有助于提升降尺度模型的预测精度（毛慧琴 等，2011）。基于此，本研究选择反照率、蒸散发和潜在蒸散发作为降尺度协变量。

反照率数据来源于MCD43A3产品，该数据集提供逐日反照率信息，空间分辨率为500 m（数据来源：[https://modis.gsfc.nasa.gov/\[2024-12-27\]](https://modis.gsfc.nasa.gov/[2024-12-27])）。数据集包含7个窄波段和3个宽波段的黑空和白空反照率数据。由于波段间差异较小且高度相关，本研究采用黑空和白空反照率的均值来计算逐日反照率（朱文哲 等，2023）。

蒸散发和潜在蒸散发数据来源于MOD16A2产品，该数据集提供逐8 d的蒸散发和潜在蒸散发数据，空间分辨率为500 m（数据来源：[https://modis.gsfc.nasa.gov/\[2024-12-27\]](https://modis.gsfc.nasa.gov/[2024-12-27])）。

2.2.5 植被指数

结合前人的研究成果，NDVI和EVI这两个植被指数能够有效反映植被覆盖度及其生长状况，从而捕捉植被对土壤水分变化的响应，提高降尺度模型在不同植被覆盖类型和水分状况下的预测精度（蔡亮红和丁建丽，2017）。归一化差异水体指数NDWI（Normalized Difference Water Index）则能有效表征地表水体分布，并与土壤湿度密切相关，尤其在水分丰富或变化较大的区域，更能精确反映土壤湿度的空间变异性（刘宇晨和高永年，2022）。因此，本研究选择NDVI、EVI和NDWI这3种植被指数作为降尺度的协变量。

NDVI和EVI数据来自MOD13A2与MYD13A2产品提供的逐8 d NDVI和EVI产品，空间分辨率为1 km（数据来源：[https://modis.gsfc.nasa.gov/\[2024-12-27\]](https://modis.gsfc.nasa.gov/[2024-12-27])）。

NDWI数据基于MOD09A1和MYD09A1产品提供的逐8 d的反射率数据（[https://modis.gsfc.nasa.gov/\[2024-12-27\]](https://modis.gsfc.nasa.gov/[2024-12-27])）计算得到，公式为

$$NDWI = \frac{l_{858\text{ nm}} - l_{1240\text{ nm}}}{l_{858\text{ nm}} + l_{1240\text{ nm}}} \tag{4}$$

式中， $l_{858\text{ nm}}$ 和 $l_{1240\text{ nm}}$ 分别对应反射率数据的中心波长为858 nm和1240 nm的反射率值。

2.2.6 土壤质地数据

土壤质地数据揭示了水分在不同土壤类型上的渗透、保持和蒸发过程的差异，从而为土壤湿

度的降尺度研究提供了关键因子（Ghafari 等，2024）。

砂土、粉砂土和黏土数据来自中国科学院资源环境科学数据中心（数据来源：[https://www.resdc.cn\[2024-12-27\]](https://www.resdc.cn[2024-12-27])），空间分辨率为1 km。数据基于1：100万土壤类型图和第二次土壤普查数据编辑而成。根据砂粒、粉砂粒和黏土粒的含量，土壤被划分为砂土、粉砂土和黏土3大类，每一类土壤通过百分比反映了不同质地颗粒的组成。

2.3 土壤湿度降尺度实验设置

本研究旨在开发精细化的土壤湿度降尺度数据产品，兼顾预测精度和模型的解释能力，同时深入分析协变量对土壤湿度变化的特征重要性。为此，基于多源土壤湿度数据的协同作用与地形汇流效应，设计了两类共11个土壤湿度降尺度模型，以全面捕捉土壤湿度的时空动态特征，并从多维度解析土壤湿度的形成机制及其驱动因素，从而提升模型的预测精度与泛化能力。

输入的卫星土壤湿度数据由于分辨率的差异性，可能对最终的降尺度结果产生影响。粗分辨率数据通过广域的气象和物理过程模拟，捕捉大尺度的土壤湿度变化，提供大范围的土壤湿度信息，并反映整体的空间分布格局。而较高分辨率数据则能够捕捉局部地区的细微变化。通过联合这些不同分辨率的数据，可以有效融合全局趋势与局部细节，弥补各自的局限和误差，从而在多尺度时空层面上提升土壤湿度模拟的准确性与可靠性。基于此，本研究整合不同分辨率的土壤湿度卫星产品，设计多种协变量组合方案，并对每种方案单独建模，以评估预测土壤湿度的最优产品组合（表2）。

表2 多源数据输入参数组合方案
Table 2 Multiple source data input parameter combination schemes

组合方案	输入参数
A	ERA5_Land
B	SMAP
C	GLDAS
D	ERA5_Land+SMAP
E	ERA5_Land+GLDAS
F	SMAP+GLDAS
G	ERA5_Land+SMAP+GLDAS

考虑到东北地区夏季频发高频暴雨天气，土壤表层湿度容易快速升高并接近饱和状态，进而产生汇流现象，尤其在土壤渗透性差或排水不良的情况下更为显著。这种汇流效应加剧了土壤湿度的空间异质性。因此，本研究引入SPI和TWI，以全面评估水文特征在土壤湿度降尺度中的作用。同时，设计了多种协变量组合方案，通过逐步增加水文特征协变量进行对比分析，探索其对土壤湿度时空分布的关键影响（表3）。

表3 地形汇流输入参数组合方案
Table 3 Confluence effect input parameter combination schemes

组合方案	输入参数
G1	无汇流因子
G2	SPI
G3	TWI
G4	SPI+TWI

2.4 土壤湿度降尺度模型

机器学习模型已广泛应用于土壤湿度降尺度研究（Zhang等，2024；周壮等，2016）。本研究选择了随机森林RF（Random Forest）、轻量梯度提升机LightGBM（Light Gradient Boosting Machine）、深度前馈神经网络DFNN（Deep Feedforward Neural Network）和卷积神经网络CNN（Convolutional Neural Network）4种算法，涵盖了集成学习、梯度提升和深度学习等主要算法类别（Srivastava等，2013；Chakrabarti等，2016）。这些方法已在相关领域的研究中得到广泛验证，具有坚实的理论基础和实践支持，可有效提升土壤湿度降尺度模型的精度与稳定性。

这4种算法对土壤湿度降尺度中不同特征和模式具有不同的适应能力。RF和LightGBM作为集成学习和梯度提升方法，能够处理非线性关系和高维特征，并且在面对复杂数据时具有较强的鲁棒性。DFNN和CNN则代表深度学习的应用，能够自动学习复杂的非线性模式，其中DFNN擅长捕捉土壤湿度与环境变量之间的关系，而CNN则能够提取空间特征，适合处理空间异质性。通过这些算法的对比与集成，能够提升降尺度模型的精度和稳定性。

实测土壤湿度数据来源于国家信息中心资料服务室，涵盖2019年—2023年的逐小时观测资料

（数据来源：<http://data.cma.cn> [2024-12-27]），其测量深度为0—10 cm。本研究基于土壤湿度产品进行降尺度分析，因此选用与土壤湿度深度（0—10 cm）基本一致的实测数据，以确保数据间的一致性。在数据处理过程中，采用随机抽样方法，将190个站点的数据用于模型训练，其余39个站点的数据用于模型验证，训练集与验证集按7：3的比例随机划分，以全面评估算法性能。

为提升模型的特征选择能力，本研究在每种算法中均引入递归特征消除RFE（Recursive Feature Elimination）方法，对特征的重要性进行排序并优化模型输入变量。下文将简要介绍所选算法的基本原理及其在本研究中的参数调整。

2.4.1 随机森林

RF是一种集成学习算法，通过构建多个决策树来进行预测。该算法通过自举抽样从训练集中随机抽取子集，每棵树采用CART（Classification and regression tree）算法进行训练，最终预测结果取所有树输出的均值（曹煜等，2023；Medrano等，2023）。该算法的优点在于集成多棵树以降低过拟合风险，增强模型的稳定性。在超参数的设置上，本研究设置决策树数量为500棵（n_estimators=500），并采用网格搜索法优化了最小样本分裂数（min_samples_split=2）和最大树深度（max_depth=30），以进一步防止过拟合并提高训练效率。

2.4.2 轻量梯度提升机

LightGBM是一种基于梯度提升决策树的学习算法。它通过利用损失函数的负梯度来逼近当前决策树的残差，并基于直方图算法加速训练过程（Sun等，2022）。此外，LightGBM支持特征并行化、数据并行化及投票并行化，能够在大规模数据集上高效运行，具有较低的内存消耗和较快的训练速度。在超参数设置方面，本研究将学习率设置为0.1（learning_rate=0.1），迭代次数设置为500次（n_estimators=500）。

2.4.3 深度前馈神经网络

DFNN是一种由多层次的全连接神经元构成的人工神经网络。DFNN通过反向传播算法计算误差梯度，并采用梯度下降法调整各层权重，从而最小化损失函数（毛勇华等，2016；Yang等，2024）。该网络通过多层的非线性变换，能够有效学习复

杂的非线性关系，适合处理土壤湿度降尺度这种大规模、高维数据。在本研究中，初始学习率设为0.001 (learning_rate=0.1)，权重衰减设为 1×10^{-5} (weight_decay= 1×10^{-5})，隐藏层数为4，每层神经元数量为512个，激活函数采用ReLU。

2.4.4 卷积神经网络

CNN是一种由卷积层、池化层和全连接层组成的神经网络 (Nomura 和 Oki, 2021)。该网络通过卷积层对输入数据进行滑动卷积，以捕捉局部区域的空间特征；池化层进一步减少特征的维度并增强网络的鲁棒性，最终通过全连接层输出结果 (Zhang 等, 2021c)。CNN通过端到端的训练方式，能够进行局部感知并共享权重，对土壤湿度这种时序数据处理具有天然优势。本研究中，初始学习率设为0.001 (learning_rate=0.001)，权重衰减设为 1×10^{-5} (weight_decay= 1×10^{-5})，使用2个卷积层，其中第一层卷积核大小为64，第二层为128，并采用最大池化层进行降维。

2.5 精度评价指标

通过比较降尺度模型预测值和实测站点数据，对土壤湿度降尺度模型进行验证。采用的评估指标包括 R^2 、RMSE和Bias。 R^2 衡量了模型对土壤湿度方差的解释程度，RMSE表示土壤湿度预测值与站点值之间的均方根差异，偏差则反映了土壤湿度预测值与真实值之间的系统性误差，揭示了模型在预测过程中的一致性偏离。综合这3个指标，可以全面评估土壤湿度降尺度模型的性能及其优缺点。各个指标计算公式如下：

$$R^2 = 1 - \frac{\sum_{i=1}^m (SMAP_{true} - SMAP_{pre})^2}{\sum_{i=1}^m (SMAP_{true} - \overline{SMAP_{pre}})^2} \tag{5}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (SMAP_{pre} - SMAP_{true})^2}{m}} \tag{6}$$

$$Bias = \frac{1}{m} \sum_{i=1}^m (SMAP_{pre} - SMAP_{true}) \tag{7}$$

式中， $SMAP_{pre}$ 为预测的土壤湿度， $SMAP_{true}$ 为实测的土壤湿度， m 为样本量。

3 结果分析

3.1 降尺度实验结果分析

3.1.1 土壤湿度产品及其协同的重要性分析

多源土壤湿度产品重要性分析结果如表4所示。不同土壤湿度数据产品的重要性存在差异，尤其在组合下，模型的表现各异。

表4 多源数据产品重要性分析

Table 4 Multi-source data product importance analysis

参数	模型	组合方案						
		A	B	C	D	E	F	G
R^2	RF	0.801	0.804	0.804	0.806	0.806	0.808	0.809
	LightGBM	0.843	0.840	0.839	0.837	0.842	0.837	0.849
	DFNN	0.813	0.813	0.809	0.822	0.823	0.820	0.824
	CNN	0.817	0.807	0.803	0.813	0.82	0.820	0.834
RMSE	RF	0.107	0.108	0.109	0.108	0.108	0.107	0.107
	LightGBM	0.097	0.098	0.098	0.099	0.097	0.099	0.095
	DFNN	0.106	0.106	0.106	0.104	0.104	0.104	0.103
	CNN	0.105	0.109	0.112	0.107	0.104	0.104	0.098
Bias	RF	0.003	0.003	0.004	0.003	0.003	0.004	0.003
	LightGBM	0.003	0.003	0.004	0.004	0.004	0.003	0.003
	DFNN	-0.004	0.004	-0.007	0.002	0.002	0.003	-0.002
	CNN	0.013	0.007	-0.008	0.012	0.011	0.026	0.009

注：A为ERA5_Land、B为SMAP、C为GLDAS、D为ERA5_Land+SMAP、E为ERA5_Land+GLDAS、F为SMAP+GLDAS、G为ERA5_Land+SMAP+GLDAS。

单独使用ERA5_Land数据时 ($R^2=0.843$, RMSE=0.097, Bias=0.003；数据均为模型中的最优数据，下同)，其预测性能优于单独使用SMAP ($R^2=0.840$, RMSE=0.098, Bias=0.003) 或GLDAS ($R^2=0.839$, RMSE=0.098, Bias=0.004)，表明ERA5_Land作为遥感数据源在土壤湿度降尺度研究中具有较强的预测能力。ERA5_Land与SMAP的组合 ($R^2=0.837$, RMSE=0.099, Bias=0.004) 与其他组合 (ERA5_Land+GLDAS、SMAP+GLDAS) 相比 ($R^2=0.842$, RMSE=0.097, Bias=0.004) 提升有限，可能由于两者在时空分辨率上的高度重叠，导致互补性较低。

当3种土壤湿度数据产品同时作为输入时，模

型的预测性能优于任意两种数据组合或单一数据源。这表明3种土壤湿度数据的融合有效弥补了单一数据源的局限性，从而提升了模型在复杂地形和时空变化区域中的预测精度。

在模型选择方面，LightGBM的表现最优 ($R^2=0.849$, $RMSE=0.095$, $Bias=0.003$)，优于CNN ($R^2=0.834$, $RMSE=0.098$, $Bias=0.009$)和DFNN ($R^2=0.824$, $RMSE=0.103$, $Bias=-0.002$)，而RF模型的性能最弱 ($R^2=0.809$, $RMSE=0.107$, $Bias=0.003$)。

LightGBM能够有效处理大规模高维数据，捕捉复杂的非线性关系，因此在降尺度任务中表现最佳；CNN擅长捕捉空间特征，但训练复杂且对数据量和计算资源要求较高；DFNN可有效处理非线性关系，但在空间特征和高维数据交互上的能力较弱；RF则由于对空间特征的捕捉不足，表现较差。

3.1.2 地形汇流因子重要性分析

地形汇流因子在土壤湿度降尺度建模中的作用如表5所示。不同地形汇流协变量组合(G1、G2、G3、G4)对模型预测能力的影响程度不一致。未考虑汇流因子时，模型的 R^2 普遍较低，表明模型拟合效果欠佳。单独采用TWI时，LightGBM模型表现 ($R^2=0.847$, $RMSE=0.094$, $Bias=0.003$) 优于仅使用SPI ($R^2=0.846$, $RMSE=0.095$, $Bias=0.003$)，表明TWI更能有效反映土壤水分的聚集特性，对降尺度贡献更大。

表5 地形汇流因子重要性分析

Table 5 Topographic confluence factor importance analysis

参数	模型	组合方案			
		G1	G2	G3	G4
R^2	RF	0.799	0.805	0.807	0.809
	LightGBM	0.843	0.846	0.847	0.849
	DFNN	0.810	0.808	0.823	0.824
	CNN	0.805	0.827	0.829	0.834
RMSE	RF	0.108	0.103	0.106	0.107
	LightGBM	0.097	0.095	0.094	0.095
	DFNN	0.105	0.106	0.101	0.103
	CNN	0.105	0.101	0.100	0.098
Bias	RF	0.004	0.004	0.004	0.003
	LightGBM	0.004	0.003	0.003	0.003
	DFNN	0.003	0.002	0.005	-0.002
	CNN	-0.0030	0.0120	-0.0090	0.009

注：G1为无汇流因子、G2为SPI、G3为TWI、G4为SPI+TWI。

当SPI和TWI同时作为协变量时，LightGBM模型精度达到最佳 ($R^2=0.849$, $RMSE=0.095$, $Bias=0.003$)，凸显了组合因子的优势。

在各个模型中，LightGBM的表现最为突出，其 R^2 值从G1的0.843提高至G4的0.849，显示出其在预测任务中的有效性。相比之下，RF在所有组合中的表现均较弱， R^2 最高仅为0.809，而DFNN和CNN则介于两者之间。

3.1.3 东北地区精细尺度土壤湿度产品

基于多源土壤湿度产品与地形汇流效应构建土壤湿度降尺度模型，将GLDAS、SMAP、ERA5_Land 3种土壤湿度数据及两种汇流因子共同纳入建模过程。图3展示了3种数据源的土壤湿度分布及降尺度结果在春、夏、秋、冬4个季节的空间分布特征。

总体来看，降尺度结果的空间分布模式与ERA5_Land湿度分布较为接近，但同时融合了GLDAS的平滑特性和SMAP的空间细节。具体分析表明，ERA5_Land数据的土壤湿度值整体偏高，而SMAP和GLDAS数据在干燥区域的分布特征存在显著差异。

降尺度结果通过多源数据的融合，在湿润区域有效细化空间边界，同时较完整地保留了干燥区域的特征。综合来看，降尺度模型通过整合多源数据与地形汇流因子，不仅有效提高了空间分辨率，还显著改善了土壤湿度的时空分布描述，尤其在局地特征细化与过渡区域识别方面表现出色。这表明降尺度方法能够在原始数据之间的差异中找到平衡，生成更加合理的土壤湿度分布模式。

在土壤湿度低值区、中值区和高值区选取的3个典型样方(75 km×75 km)降尺度后的土壤湿度分布结果见图4。总体来看，降尺度结果与原始数据的分布趋势一致，高值和低值中心的位置匹配度较高，同时呈现出更多空间细节，边界过渡更为平滑。在低湿度区域，降尺度结果准确反映了干燥分布的总体趋势，并能捕捉局地细微的空间变化；在中湿度区域，降尺度结果强化了湿润区域与干燥区域之间的空间梯度，过渡带表现清晰，细节刻画更加丰富；在高湿度区域，降尺度结果进一步细化了湿润中心的空间分布特征，边界更加明确。尽管降尺度结果整体表现良好，但仍存在少量斑块化现象，这可能与输入的3种土壤湿度数据产品本身较低的空间分辨率有关。




图3 降尺度结果整体图
Fig. 3 Overall picture of downscaling results




图4 降尺度结果细节图
Fig. 4 Downscaling results detail diagram

3.2 土壤湿度降尺度协变量重要性分析

总体而言，土壤湿度数据产品（ERA5_Land、SMAP、GLDAS）在降尺度模型中占据主导地位，表明这些数据在揭示土壤湿度时空特征方面具有客观性和准确性。图5显示了降尺度模型中各协变

量的重要性排序。
ERA5-Land、SMAP因其较高的时间分辨率和广泛的观测覆盖范围，提升了降尺度模型对土壤湿度季节性变化的捕捉能力，而GLDAS作为融合气象和水文模拟的产品，虽能提供相对稳定的土壤湿度背景，但由于分辨率较低，其对模型的贡献相对较小。因此，在特征重要性排序中，ERA5_Land、SMAP排序更为靠前，GLDAS排序稍后。

地形和水文特征是除土壤湿度产品外最为重要的特征。坡向和汇流特征（如SPI和TWI）在所有模型中均表现出较高的重要性，反映了地形对土壤湿度空间分布的调控作用。特别是在降水量频繁的东北地区，汇流现象加剧了土壤湿度的空间异质性，而坡向变量能够提升模型在复杂地形区域的预测能力。与之相辅相成，水体相关协变量（如NDWI）重要性评分较高，反映了水体分布对土壤湿度变化的影响，尤其在湿润环境中，水体的存在能够增强湿度梯度的空间表现。

气象变量的重要性则相对较低，且其贡献模式具有明显的模型依赖性。其中，气温对模型的

贡献普遍较低,在各模型中排名均靠后。而降水量的作用则因模型而异,尤其在LightGBM中表现出相对更高的重要性,但在其他模型中则排在中

部及偏后位置。这反映了不同算法在捕捉降水量这一驱动因子与土壤湿度间的复杂关系时,其机制与效率存在差异。




图5 特征重要性结果

Fig. 5 Feature importance results

相比之下,反照率与潜在蒸散发等地表参数在各模型中的重要性排序存在差异。这可能是由于其在逐日尺度上的变化相对平稳,与土壤湿度的高频波动关联性不强,因此在捕捉快速动态方面的作用有限。此外,植被指数(NDVI、EVI)与土壤质地(砂土、粉砂土)等协变量对模型性能的提升作用相对较小,其在当前降尺度框架中的解释能力尚不明显。

3.3 降尺度结果验证与性能评估

3.3.1 原位验证结果

以39个实测站点数据作为参考,进一步验证降尺度后的土壤湿度结果与3种土壤湿度数据产品的匹配性(图6)。结果表明,降尺度结果的相关系数(r)中位数最高($r=0.925$),明显优于ERA5_Land($r=0.786$)、SMAP($r=0.691$)和GLDAS($r=0.622$)。在RMSE和Bias方面,SMAP数据的拟合

效果稍好于ERA5_Land,而GLDAS因其较低的空间分辨率,拟合效果较差。总体来看,降尺度结果在 r 、RMSE和Bias等各项指标上均显著优于这3种土壤湿度数据产品,充分证明了本研究所构建降尺度模型的有效性。

在每个省内各抽取一个站点进一步验证降尺度结果的时间序列表现(图7)。需要注意的是,第3个站点的实测数据部分缺失,仅覆盖第112天到第317天的观测记录。结果显示,降尺度结果的时间序列趋势与实测数据高度吻合,表明模型能够有效捕捉土壤湿度的时序变化。然而,模型在某些时段(如第92—120天和第142—155天)出现了明显的高估现象,这可能与模型在特定时间段对气象变量或其他输入特征的过度响应有关。尽管如此,整体来看,降尺度结果的曲线趋势与实测数据保持高度一致,进一步验证了模型的可靠性和精度。




图6 降尺度结果与3种产品数据的原位验证对比


Fig. 6 The downscaling results were compared with the *in-situ* validation of three product data

图7 降尺度结果与3种产品数据的原位验证对比

Fig. 7 The downscaling results were compared with the *in situ* validation of three product data

3.3.2 降尺度模型精度的横向评估

本研究将所提出的降尺度产品与输入的3种土壤湿度产品及近期主要的土壤湿度降尺度方法进

行了横向比较 (表6)。首先, 通过与输入产品的精度对比表明, GLDAS、SMAP和ERA5-Land在东北三省与站点观测的 R^2 分别为0.384、0.261和0.372,

说明三者均能捕捉到该区域土壤湿度变化的部分信号，尽管质量存在一定偏差，但仍可作为降尺度模型的输入数据基础。经过降尺度处理后，模型的 R^2 提升至0.849，表明在提高空间分辨率的同时，数据质量也得到了改善。

表6 模型精度对比分析
Table 6 Comparison of model accuracy

比较项	模型/方法	评估区域	R^2	RMSE	Bias
输入产品	GLDAS(Hong等,2024)	东北三省	0.384	0.09	0.05
	SMAP(Hong等,2024)	东北三省	0.261	0.08	0.08
	ERA5_Land(Hong等,2024)	东北三省	0.372	0.12	0.105
横向实验	Sishah等(2023)的方法	阿瓦什河流域(2021年)	0.471	0.07	-0.036
	Shangguan等(2023)的方法	青藏高原(2015年—2019年)	0.67	0.084	-0.064
	Xu等(2024)的方法	闪电河流域(2015年—2019年)	0.779	0.073	0.041
本研究结果	GLDAS、SMAP、ERA5_Land	东北地区(2019年—2023年)	0.849	0.095	0.003

其次，与其他近期研究的横向对比可以看出：Sishah等（2023）采用的基于创新协变量的机器学习方法，在阿瓦什河流域的研究中实现了 R^2 为0.471；Shangguan等（2023）采用的将统计方法与机器学习相结合的方法取得了 R^2 为0.67的结果；Xu等（2024）采用的机理与深度学习相结合的方法，达到了 R^2 为0.779的精度。相比之下，本研究在保持最低Bias的同时，取得 R^2 为0.849的表现。

与此同时，本研究的RMSE值相较于其他研究较高，这一现象可以从两方面进行阐述。首先，输入产品的精度与空间分辨率密切相关。研究表明，随着空间分辨率的精细化，RMSE值通常呈现增加趋势（Maslanka等，2022）。本研究降尺度后的土壤湿度数据的空间分辨率为1 km，相较于原始土壤湿度产品，其更为精细的空间刻画能力增强了局部变异性，从而导致RMSE值相对较高。其次，本研究的研究区域范围较大，而横向对比的相关研究以流域为研究对象，区域范围较小。较大的研究区域不可避免的累积了更多子区域的误差，进一步推高了整体的RMSE值。这一问题的详细论证可参见4.4节。

综合而言，本研究提出的降尺度方法在整体效果上优于其他研究，为土壤湿度的高精度估算提供了有力支撑，并有助于提升数据的空间解析能力和应用价值。

4 讨论

4.1 多源多尺度数据产品协同提升土壤湿度降尺度模型精度

根据多源数据产品的分析结果，融合ERA5_

Land、SMAP、GLDAS 3种数据源时，降尺度模型精度最高，这主要得益于三者数据特性差异、空间分辨率和方法互补性方面的优势（表7）。

首先，土壤湿度表征原理的多样性是精度提升的关键因素。ERA5_Land侧重于气象条件对土壤湿度的影响，尤其适用于捕捉大尺度气候条件下的土壤湿度变化；GLDAS侧重于物理过程驱动模式，如蒸发、降水量和土壤水分的渗透；SMAP则通过卫星遥感直接观测土壤湿度，能够提供高精度的表层土壤湿度数据（Abbaszadeh等，2019；Wu等，2021；程善俊等，2013）。三者在土壤湿度获取和模拟方法上的差异，使其能够从不同视角提供互补信息。具体而言，ERA5_Land和GLDAS通过气象和物理模拟估算土壤湿度，而SMAP则通过同化其亮温数据到陆面模型中来估算土壤湿度，从而在数据融合中弥补各自的局限性，提高降尺度模型精度。

其次，不同数据源的特性差异导致其各自存在系统性误差或偏差，但彼此之间又具有互补关系。ERA5_Land基于集合四维变分同化系统，通过大气强迫和地表模拟更新状态，土壤湿度作为次要变量通过大气驱动间接推导，可能在特定气象条件下引入一定误差（Muñoz-Sabater等，2021）；SMAP则通过SMAP卫星观测亮度温度数据，结合Catchment模型同化反演土壤湿度（Entekhabi等，2010），并受云层覆盖和卫星视角等因素影响；GLDAS虽整合了多个气象源（GDAS（Global Data Assimilation System）、GPCP（Global Precipitation Climatology Project）和AGRMET（Air Force Weather Agency’s Agricultural Meteorological modeling

system))，但基于陆面模式同化多源数据，可能在强迫数据不足或数据源不匹配时引入传递误差导致数据不一致 (Rodell 等，2004)。通过结合这些数据源，可以有效弥补各自的误差与偏差，从而提升整体模拟结果的精度。此外，区域土壤水分多尺度时空描述在一定程度上提升了模型的土壤

湿度降尺度的能力。ERA5_Land和SMAP提供的较高空间分辨率数据可以捕捉到局部地区的细微变化，而GLDAS的数据则可提供更大范围的背景信息。融合不同尺度产品的特性，模型能够更好地利用细节信息和全局趋势，全面反映土壤湿度的时空变化，从而提升模拟的准确性与可靠性。

表7 土壤湿度产品数据对比
Table 7 Soil moisture product data comparison

模型	对比参数				
	观测数据来源	同化模型	与大气的动态一致性	优势	劣势
ERA5_Land	全球气象站、卫星观测 (GNSS-R、ASCAT)、气象模式驱动数据	ECMWF 的陆面模型	较好,受控于大气模式的物理方程约束	动态约束强、全球一致性高	土壤湿度通过模式间接推导,精度受限于大气误差
SMAP	SMAP 被动遥感微波辐射计、降水量数据	Catchment 陆面模型	一般,通过卫星数据及物理模型反映土壤湿度的实际状况	依赖于卫星观测数据	数据易受植被覆盖和地表粗糙度等干扰
GLDAS	地面站、卫星数据 (TRMM、MODIS)和再分析数据	Noah 陆面模型	动态一致性依赖于模型选择和参数设置	数据来源多样,适用范围广	动态一致性不如 ERA5_Land,分辨率低于 SMAP

注：GNSS-R(global navigation satellite system reflectometry)为全球导航卫星系统反射测量、ASCAT(advanced scatterometer)为C波段微波散射计、TRMM(tropical rainfall measuring mission)为热带降雨测量任务卫星、MODIS(moderate-resolution imaging spectroradiometer)为中分辨率成像光谱仪。

4.2 基于地形汇流的降尺度优化

根据地形汇流实验的分析结果，地形汇流因子SPI和TWI同时加入时对降尺度模型精度提升最大。地形汇流过程是影响土壤湿度空间分布的核心机制之一 (张彩霞 等，2005)。SPI和TWI已被应用于研究水文过程的空间尺度效应、确定地球化学模型的水文流动路径、洪水监测和滑坡分析等领域，并已被证实与土壤湿度的空间分布具有良好的相关性 (Tehrany 等，2014；Yilmaz，2009；Beven 等，1988；Robson 等，1992)。

SPI和TWI从不同的地形属性角度反映了土壤湿度的空间变化特征。SPI描述了地表某点的潜在水流汇聚能力，主要由流域面积和坡度决定 (Tarolli，2015)。流域面积反映了上游的供水能力，而坡度则影响水流的速度 (邓慧平和李秀彬，2002)。因此，SPI能够有效表征局地水文条件的动态特性，为土壤湿度的分布提供重要信息。TWI则从另一视角量化地形对水文过程的控制，通过结合坡度与单位宽度的上游贡献面积，描述局

地积水能力和排水效率，揭示土壤湿度的空间积聚效应 (Sørensen 等，2006)。两者从动态和静态两个方面补充了土壤湿度的分布信息，从而提升降尺度模型的精度。

TWI在提升降尺度模型精度方面的作用比SPI更为显著，因为其更全面地反映了地形汇流对土壤湿度的直接影响。TWI通过坡度和积水面积的综合表征，量化了局地水分积聚能力，尤其能够捕捉低洼地区或流域汇水区的水文特征，与土壤湿度的空间分布具有高度相关性 (王海力 等，2016；包黎莉 等，2011)。相比之下，虽然SPI也与地形汇流有关，但其主要关注坡度与水流侵蚀能力之间的关系，更偏向于对动态水流过程的描述 (Moayedi 等，2019)。由于土壤湿度的分布更直接受到积水特征的影响，TWI对模型的贡献集中于描述水分在地形上的积聚与存留，从而能更有效地优化降尺度模型的精度。SPI在此过程中提供了补充信息，其作用更多体现在与其他因子的配合上。

4.3 时间特征对降尺度影响的双重性

由于气象数据（地表温度、降水量）的时间动态性强，其变化对土壤湿度的影响具有时效性。因此本研究考虑了时间特征及其滞后效应，设计了4种涵盖多种时间特征情境的研究方案（表8）。

从时间特征的角度来看，3种模型的最高精度均出现在T2方案，这表明时间特征对土壤湿度降尺度具有重要作用（图8）。与T1方案相比，T2方案的 R^2 值提高了0.014—0.053，进一步验证了土壤湿度对短期气象变化的敏感性。然而，随着时间滞后气象特征的引入（从T2方案到T3、T4方案），模型精度有所下降， R^2 降幅为0.005—0.012。

因此，时间特征的引入对土壤湿度降尺度具有双重作用，即时间特征可显著提升模型精度，而滞后特征则可能降低模型性能。

表8 时间特征输入参数组合方案
Table 8 Time effect input parameter combination schemes

组合方案	输入参数
T1	全部特征
T2	全部特征+时间特征
T3	的全部特征+时间特征+Pre_8 d+LST_8 d
T4	全部特征+时间特征+Pre_8 d+LST_8 d+Pre_16 d+LST_16 d

注：Pre_8 d和LST_8 d代表倒推8 d的气温和降水量，Pre_16 d和LST_16d代表倒推16 d的气温和降水量；时间特征表示当前土壤湿度所在年份中的具体天数；全部特征为表1中的全部协变量。




图8 不同模型及不同组合方案下的时间特征结果

Fig. 8 Results of the time feature under different models and different combination schemes

当天时间特征能够提升土壤湿度降尺度模型的精度，主要原因在于土壤湿度具有显著的季节

性和日变化特征，而时间特征可间接捕捉这些规律（邱扬等，2007；Kempainen等，2023）。在季

节变化层面，土壤湿度受气象因子的周期性驱动，将时间特征引入模型，相当于为其提供一种简洁方式来标记这些周期变化；在日变化层面，短时降水降水或白天蒸散发的影响会迅速反映在当天的表层土壤湿度中，使当天时间特征能够为降尺度模型提供关键信息（Wu等，2021）。

相比之下，滞后时间特征更多反映过去气象事件的累积效应，这种效应对深层土壤湿度的影响更为显著，但在表层土壤湿度中的表现可能已被快速水分交换过程所削弱（Nazarieh等，2018；Xu等，2021a）。随着滞后时间的延长，变量与土壤湿度的相关性进一步减弱，模型难以聚焦于关键动态变化，同时受到复杂权重分配和冗余变量干扰的影响，性能随之下降（刘英等，2022）。表层土壤湿度的变化通常由实时降水、蒸发及气象条件主导，当天时间特征可准确捕捉这些快速变化规律，而滞后时间特征则可能引入无效信息或噪声，最终降低模型精度。

4.4 模型精度的时空变异特征

本研究分别对模型精度的时空变化差异进行了相关分析。首先是精度指标的时间变化。根据表9中春、夏、秋、冬四季的模型精度指标，RMSE存在明显的时间尺度波动性，其数值从夏季最低值0.034升至冬季最高值0.132，变异幅度约为288%。尽管Bias在各个季节保持相对稳定，但RMSE的季节性差异表明，模型误差主要来源于环境动态变化所引发的随机不确定性。冬季RMSE的异常高值与积雪覆盖导致的遥感反演偏差相关，此类空间异质性使得局部积雪覆盖子区域的RMSE显著高于其他区域，进而拉高全局RMSE（Hogg，2004）。

表9 精度的时间变异特征

Table 9 Time variation characteristics of accuracy			
季节	R^2	RMSE	Bias
春	0.803	0.109	0.004
夏	0.906	0.034	0.002
秋	0.857	0.046	0.003
冬	0.793	0.132	0.002

其次是精度指标的空间变化。对比表10不同空间尺度的模型精度指标，发现随着空间范围的扩大， R^2 逐步提升（0.791→0.849），但是RMSE与

Bias也相应增加。这一现象与Doubková等（2014）关于土壤湿度数据误差的研究结论具有相似性：在较小的空间尺度上，模型的局部噪声（如数据采集误差或环境异质性）对RMSE贡献显著；而随着空间尺度的扩展，空间异质性（不同地理单元的气候、土壤差异）和参考数据的不确定性成为主导的误差来源，更大范围内子区域误差的累积效应致使RMSE的误差增大。

表10 精度的空间变异特征

Table 10 Spatial variation characteristics of accuracy			
空间尺度	R^2	RMSE	Bias
市	0.791	0.075	0.001
省	0.843	0.089	0.002
研究区	0.849	0.095	0.003

4.5 方法不确定性分析

本研究所提出的方法仍存在一些不确定性。首先，在构建与验证降尺度模型过程中，不同空间尺度数据的匹配仍存在一定问题。为生成土壤湿度降尺度产品，高分辨率遥感数据、地形因子数据和土壤质地数据需重采样至较低分辨率，这一过程不可避免地引入误差。其次，在模型验证阶段，直接将实测站点数据与1 km分辨率的降尺度结果对比，可能引入额外的不确定性，从而影响结果的可靠性。此外，由于研究区域的时间范围受限，模型训练样本量不足，未能充分考虑更多极端气候事件及土壤湿度的空间分布模式，这可能会影响模型对极端情况的预测能力。

5 结 论

针对现有土壤湿度降尺度方法中数据产品单一及协变量考虑不足的问题，本研究提出了一种融合ERA5_Land、SMAP和GLDAS 3种土壤湿度数据产品，并引入地形汇流特征（SPI和TWI）的土壤湿度降尺度方法。通过集成多源数据和关键协变量，生成了1 km分辨率的逐日土壤湿度数据产品，为改进降尺度模型提供了新思路。研究结果表明，该方法提升了土壤湿度降尺度模型的精度和时空一致性。

（1）3种土壤湿度数据产品因来源和空间尺度差异，从不同角度提供了互补信息，从而有效提升土壤湿度降尺度模型的整体精度。

（2）SPI和TWI通过反映汇流过程对土壤湿度

的静态与动态影响,提升了土壤湿度降尺度模型对土壤湿度空间分布的拟合能力。

(3) 本方法得到的土壤湿度数据产品精度较高,降尺度的最优结果为 $R^2=0.849$ 、 $RMSE=0.095$ 、 $Bias=0.003$ 。与 RF、CNN 和 DFNN 模型相比,LightGBM 表现更优,是土壤湿度降尺度的最佳模型。降尺度后的土壤湿度能够较好地反映实测数据的变化趋势,且具有较强的时空一致性。

综上所述,本研究方法有效解决了现有土壤湿度降尺度模型的局限性,生成的高分辨率土壤湿度数据产品为农业精准灌溉、水文模拟及生态监测提供了重要支持。

未来研究可以聚焦于提升模型在不同气候和地形条件下的适应性,以增强其在全球范围内的应用潜力。此外,结合更多遥感数据和地面观测资料,有望进一步优化降尺度模型精度,为跨尺度土壤湿度监测提供更为精确的支持。

参考文献(References)

Abbaszadeh P, Moradkhani H and Zhan X W. 2019. Downscaling SMAP radiometer soil moisture over the CONUS using an ensemble learning method. *Water Resources Research*, 55(1): 324-344 [DOI: 10.1029/2018WR023354]

Bao L L, Qin C Z and Zhu A X. 2011. Quantitative error assessment of topographic wetness index algorithms. *Progress in Geography*, 30(1): 57-64 (包黎莉, 秦承志, 朱阿兴. 2011. 地形湿度指数算法误差的定量评价. 地理科学进展, 30(1): 57-64) [DOI: 10.11820/dlkxjz.2011.01.007]

Beven K J, Wood E F and Sivapalan M. 1988. On hydrological heterogeneity—Catchment morphology and catchment response. *Journal of Hydrology*, 100(1/3): 353-375 [DOI: 10.1016/0022-1694(88)90192-8]

Cai L H and Ding J L. 2017. Remote sensing inversion of soil moisture based on modified vegetation index. *Arid Land Geography*, 40(6): 1248-1255 (蔡亮红, 丁建丽. 2017. 基于改进植被指数土壤水分遥感反演. 干旱区地理, 40(6): 1248-1255) [DOI: 10.13826/j.cnki.cn65-1103/x.2017.06.015]

Cai Z. 2010. Research on Sustainable Agricultural Development of Northeast Black Soil Zone. Changchun: Jilin University (蔡壮. 2010. 东北黑土区农业可持续发展研究. 长春: 吉林大学)

Cao Y, Fang X Q, Yang L L, Jiang X Y, Liao M Y and Ren L L. 2023. Downscaling of CCI soil moisture in the Xiliaohe River Basin based on random forest. *Journal of Geo-Information Science*, 25(8): 1669-1681 (曹煜, 方秀琴, 杨露露, 蒋心远, 廖美玉, 任立良. 2023. 基于随机森林的西辽河流域 CCI 土壤湿度降尺度研究. 地球信息科学学报, 25(8): 1669-1681) [DOI: 10.12082/dqxxkx.2023.221013]

Cao Y P, Jin R, Han X J and Li X. 2011. A downscaling method for AMSR-E soil moisture using MODIS derived dryness index. *Remote Sensing Technology and Application*, 26(5): 590-597 (曹永攀, 晋锐, 韩旭军, 李新. 2011. 基于 MODIS 和 AMSR-E 遥感数据的土壤水分降尺度研究. 遥感技术与应用, 26(5): 590-597)

Carlson T N, Gillies R R and Perry E M. 1994. A method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover. *Remote Sensing Reviews*, 9(1/2): 161-173 [DOI: 10.1080/02757259409532220]

Chakrabarti S, Judge J, Bongiovanni T, Rangarajan A and Ranka S. 2016. Spatial scaling of satellite soil moisture using temporal correlations and ensemble learning. *arXiv*: 1601.05767 [DOI: 10.48550/arXiv.1601.05767]

Chen J, Jönsson P, Tamura M, Gu Z H, Matsushita B and Eklundh L. 2004. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. *Remote Sensing of Environment*, 91(3/4): 332-344 [DOI: 10.1016/j.rse.2004.03.014]

Chen Q, Zeng J Y, Cui C Y, Li Z, Chen K S, Bai X J and Xu J. 2018. Soil moisture retrieval from SMAP: a validation and error analysis study using ground-based observations over the little Washita watershed. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3): 1394-1408 [DOI: 10.1109/TGRS.2017.2762462]

Chen S Q, Zhang G H, Zhu P Z, Wang C S and Wan Y Q. 2023. Impact of land use type on soil erodibility in a small watershed of rolling hill northeast China. *Soil and Tillage Research*, 227: 105597 [DOI: 10.1016/j.still.2022.105597]

Cheng S J, Guan X D, Huang J P and Ji M X. 2013. Analysis of response of soil moisture to climate change in semi-arid loess Plateau in China based on GLDAS data. *Journal of Arid Meteorology*, 31(4): 641-649 (程善俊, 管晓丹, 黄建平, 季明霞. 2013. 利用 GLDAS 资料分析黄土高原半干旱区土壤湿度对气候变化的响应. 干旱气象, 31(4): 641-649) [DOI: 10.11755/j.issn.1006-7639(2013)-04-0641]

Deng H P and Li X B. 2002. Relationship of upslope contribution area and soil water content in TOPMODEL. *Progress in Geography*, 21(2): 103-110 (邓慧平, 李秀彬. 2002. 地形指数的物理意义分析. 地理科学进展, 21(2): 103-110) [DOI: 10.3969/j.issn.1007-6301.2002.02.002]

Deng Y C and Xu Y H. 2007. Introduction to the methods of soil moisture content measuring. *Hydrology*, 27(4): 20-24 (邓英春, 许永辉. 2007. 土壤水分测量方法研究综述. 水文, 27(4): 20-24) [DOI: 10.3969/j.issn.1000-0852.2007.04.005]

Doubkova M, Dostalova A, Van Dijk A I J M, Blöschl G, Wagner W and Fernandez-Prieto D. 2014. How do spatial scale, noise, and reference data affect empirical estimates of error in ASAR-Derived 1 km resolution soil moisture?. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(9): 3880-3891 [DOI: 10.1109/JSTARS.2014.2324657]

Entekhabi D, Njoku E G, O'Neill P E, Kellogg K H, Crow W T, Edelstein W N, Entin J K, Goodman S D, Jackson T J, Johnson J, Kimball J, Piepmeier J R, Koster R D, Martin N, McDonald K C,

- Moghaddam M, Moran S, Reichle R, Shi J C, Spencer M W, Thurman S W, Tsang L and Van Zyl J. 2010. The soil moisture active passive (SMAP) mission. *Proceedings of the IEEE*, 98(5): 704-716 [DOI: 10.1109/JPROC.2010.2043918]
- Ghafari E, Walker J P, Zhu L J, Colliander A and Faridhosseini A. 2024. Spatial downscaling of SMAP radiometer soil moisture using radar data: application of machine learning to the SMAPEX and SMAPVEX campaigns. *Science of Remote Sensing*, 9: 100122 [DOI: 10.1016/j.srs.2024.100122]
- Hogg J. 2004. Quantitative remote sensing of land surfaces. *The Photogrammetric Record*, 19(108): 413-415 [DOI: 10.1111/j.0031-868X.2004.295_1.x]
- Hong X, Jia S F, Zhu W B and Song Z K. 2024. Evaluation of global seamless soil moisture products over China: a perspective of soil moisture sensitivity to precipitation. *Journal of Hydrology*, 641: 131789 [DOI: 10.1016/J.JHYDROL.2024.131789]
- Ji P, Yuan X and Liang X Z. 2017. Do lateral flows matter for the hyperresolution land surface modeling?. *Journal of Geophysical Research: Atmospheres*, 122(22): 12077-12092 [DOI: 10.1002/2017JD027366]
- Kemppinen J, Niittynen P, Rissanen T, Tyystjärvi V, Aalto J and Luoto M. 2023. Soil moisture variations from boreal forests to the tundra. *Water Resources Research*, 59(6): e2022WR032719 [DOI: 10.1029/2022WR032719]
- Kogan F N. 1998. Global drought and flood-watch from NOAA polar-orbiting satellites. *Advances in Space Research*, 21(3): 477-480 [DOI: 10.1016/S0273-1177(97)00883-1]
- Liu Y, He X, Yue H and Wei J L. 2022. Inversion of soil moisture based on moving window method with convolutional neural network. *Remote Sensing Information*, 37(2): 16-22 (刘英, 何雪, 岳辉, 魏嘉莉. 2022. 利用移动窗口卷积神经网络反演土壤湿度. 遥感信息, 37(2): 16-22) [DOI: 10.3969/j.issn.1000-3177.2022.02.003]
- Liu Y C and Gao Y N. 2022. Surface water extraction in Yangtze River Basin based on sentinel time series image. *National Remote Sensing Bulletin*, 26(2): 358-372 (刘宇晨, 高永年. 2022. Sentinel时序影像的长江流域地表水体提取. 遥感学报, 26(2): 358-372) [DOI: 10.11834/jrs.20211287]
- Lu J G, Wang H T, He X D and Gao Y B. 2006. Responses of *Artemisia ordosica* population to soil moisture spatial heterogeneity on semi-fixed dune of Mu Us sandy land. *Chinese Journal of Applied Ecology*, 17(8): 1469-1474 (卢建国, 王海涛, 何兴东, 高玉葆. 2006. 毛乌素沙地半固定沙丘油蒿种群对土壤湿度空间异质性的响应. 应用生态学报, 17(8): 1469-1474) [DOI: 10.13287/j.1001-9332.2006.0291]
- Madhukumar N, Wang E, Fookes C and Xiang W. 2022. 3-D Bi-directional LSTM for satellite soil moisture downscaling. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5414018 [DOI: 10.1109/TGRS.2022.3227108]
- Mao H Q, Yan X D, Xiong Z and Tian H Q. 2011. Modeled impact of irrigation on regional climate in India. *Acta Ecologica Sinica*, 31(4): 1038-1045 (毛慧琴, 延晓冬, 熊喆, 田汉勤. 2011. 农田灌溉对印度区域气候的影响模拟. 生态学报, 31(4): 1038-1045) [DOI: 10.20103/j.stxb.2011.04.016]
- Mao Y H, Gui X L, Li Q and He X S. 2016. Study on application technology of deep learning. *Application Research of Computers*, 33(11): 3201-3205 (毛勇华, 桂小林, 李前, 贺兴时. 2016. 深度学习应用技术研究. 计算机应用研究, 33(11): 3201-3205) [DOI: 10.3969/j.issn.1001-3695.2016.11.001]
- Maslanka W, Morrison K, White K, Verhoef A and Clark J. 2022. Retrieval of sub-kilometric relative surface soil moisture with Sentinel-1 utilizing different backscatter normalization factors. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4410613 [DOI: 10.1109/TGRS.2022.3175256]
- McNairn H, Jackson T J, Wiseman G, Belair S, Berg A, Bullock P, Colliander A, Cosh M H, Kim S B, Magagi R, Moghaddam M, Njoku E G, Adams J R, Homayouni S, Ojo E, Rowlandson T, Shang J L, Goita K and Hosseini M. 2015. The soil moisture active passive validation experiment 2012 (SMAPVEX12): prelaunch calibration and validation of the SMAP soil moisture algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5): 2784-2801 [DOI: 10.1109/TGRS.2014.2364913]
- Medrano S C, Satgé F, Molina-Carpio J, Zolá R P and Bonnet M P. 2023. Downscaling daily satellite-based precipitation estimates using MODIS cloud optical and microphysical properties in machine-learning models. *Atmosphere*, 14(9): 1349 [DOI: 10.3390/atmos14091349]
- Meng C L, Jin H D and Zhang W L. 2023. Lateral terrestrial water flow schemes for the Noah-MP land surface model on both natural and urban land surfaces. *Journal of Hydrology*, 620: 129410 [DOI: 10.1016/j.jhydrol.2023.129410]
- Merlin O, Chehbouni A, Walker J P, Panciera R and Kerr Y H. 2008. A simple method to disaggregate passive microwave-based soil moisture. *IEEE Transactions on Geoscience and Remote Sensing*, 46(3): 786-796 [DOI: 10.1109/TGRS.2007.914807]
- Moayedi H, Mehrabi M, Mosallanezhad M, Rashid A S A and Pradhan B. 2019. Modification of landslide susceptibility mapping using optimized PSO-ANN technique. *Engineering with Computers*, 35(3): 967-984 [DOI: 10.1007/s00366-018-0644-0]
- Mohanty B P, Cosh M H, Lakshmi V and Montzka C. 2017. Soil moisture remote sensing: state-of-the-science. *Vadose Zone Journal*, 16(1): 1-9 [DOI: 10.2136/vzj2016.10.0105]
- Mueller R, Trentmann J, Träger-Chatterjee C, Posselt R and Stöckli R. 2011. The role of the effective cloud albedo for climate monitoring and analysis. *Remote Sensing*, 3(11): 2305-2320 [DOI: 10.3390/rs3112305]
- Muñoz-Sabater J, Dutra E, Agustí-Panareda A, Albergel C, Arduini G, Balsamo G, Boussetta S, Choulga M, Harrigan S, Hersbach H, Martens B, Miralles D G, Piles M, Rodríguez-Fernández N J, Zsoter E, Buontempo C and Thépaut J N. 2021. ERA5-Land: a state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9): 4349-4383 [DOI: 10.5194/essd-13-4349-2021]
- Nazarieh F, Ansari H, Ziari A N, Izady A, Davari K and Brunner P. 2018. Spatial and temporal dynamics of deep percolation, lag

- time and recharge in an irrigated semi-arid region. *Hydrogeology Journal*, 26(7): 2507-2520 [DOI: 10.1007/s10040-018-1789-z]
- Niu G Y, Yang Z L, Mitchell K E, Chen F, Ek M B, Barlage M, Kumar A, Manning K, Niyogi D, Rosero E, Tewari M and Xia Y L. 2011. The community Noah land surface model with multiparameterization options (Noah-MP): 1. Model description and evaluation with local-scale measurements. *Journal of Geophysical Research*, 116(D12): D12109 [DOI: 10.1029/2010JD015139]
- Nomura R and Oki K. 2021. Downscaling of MODIS NDVI by using a convolutional neural network-based model with higher resolution SAR data. *Remote Sensing*, 13(4): 732 [DOI: 10.3390/rs13040732]
- Peng J, Loew A, Merlin O and Verhoest N E C. 2017. A review of spatial downscaling of satellite remotely sensed soil moisture. *Reviews of Geophysics*, 55(2): 341-366 [DOI: 10.1002/2016RG000543]
- Qin X D, Pang Z G, Jiang W, Feng T S and Fu J E. 2021. Progress and development trend of soil moisture microwave remote sensing retrieval method. *Journal of Geo-Information Science*, 23(10): 1728-1742 (覃湘栋, 庞治国, 江威, 冯天时, 付俊娥. 2021. 土壤水分微波反演方法进展和发展趋势. *地球信息科学学报*, 23(10): 1728-1742) [DOI: 10.12082/dqxxkx.2021.210104]
- Qiu Y, Fu B J, Wang J, Zhang X L and Meng Q H. 2007. Spatiotemporal variation of soil moisture and its relation to environmental factors. *Chinese Journal of Ecology*, 26(1): 100-107 (邱扬, 傅伯杰, 王军, 张希来, 孟庆华. 2007. 土壤水分时空变异及其与环境因子的关系. *生态学杂志*, 26(1): 100-107) [DOI: 10.13292/j.1000-4890.2007.0020]
- Robock A, Vinnikov K Y, Srinivasan G, Entin J K, Hollinger S E, Speranskaya N A, Liu S X and Namkhay A. 2000. The global soil moisture data bank. *Bulletin of the American Meteorological Society*, 81(6): 1281-1299 [DOI: 10.1175/1520-0477(2000)081<1281:TGSMDB>2.3.CO;2]
- Robson A, Beven K and Neal C. 1992. Towards identifying sources of subsurface flow: a comparison of components identified by a physically based runoff model and those determined by chemical mixing techniques. *Hydrological Processes*, 6(2): 199-214 [DOI: 10.1002/hyp.3360060208]
- Rodell M, Houser P R, Jambor U, Gottschalk J, Mitchell K, Meng C J, Arsenault K, Cosgrove B, Radakovich J, Bosilovich M, Entin J K, Walker J P, Lohmann D and Toll D. 2004. The global land data assimilation system. *Bulletin of the American Meteorological Society*, 85(3): 381-394 [DOI: 10.1175/BAMS-85-3-381]
- Rodhe A and Seibert J. 1999. Wetland occurrence in relation to topography: a test of topographic indices as moisture indicators. *Agricultural and Forest Meteorology*, 98-99: 325-340 [DOI: 10.1016/S0168-1923(99)00104-5]
- Sabaghy S, Walker J P, Renzullo L J and Jackson T J. 2018. Spatially enhanced passive microwave derived soil moisture: capabilities and opportunities. *Remote Sensing of Environment*, 209: 551-580 [DOI: 10.1016/j.rse.2018.02.065]
- Senanayake I P, Pathira Arachchilage K R L, Yeo I Y, Khaki M, Han S C and Dahlhaus P G. 2024. Spatial downscaling of satellite-based soil moisture products using machine learning techniques: a review. *Remote Sensing*, 16(12): 2067 [DOI: 10.3390/rs16122067]
- Shangguan Y L, Min X X and Shi Z. 2023. Inter-comparison and integration of different soil moisture downscaling methods over the Qinghai-Tibet Plateau. *Journal of Hydrology*, 617: 129014 [DOI: 10.1016/j.jhydrol.2022.129014]
- Sharma J, Prasad R, Srivastava P K, Yadav S A, Singh S K and Verma B. 2024. Development of a new vegetation modulated soil moisture index for the spatial disaggregation of SMAP soil moisture data product. *Physics and Chemistry of the Earth, Parts A/B/C*, 135: 103594 [DOI: 10.1016/j.pce.2024.103594]
- Sishah S, Abraham T, Azene G, Dessalew A and Hundera H. 2023. Downscaling and validating SMAP soil moisture using a machine learning algorithm over the Awash River basin, Ethiopia. *PLoS One*, 18(1): e0279895 [DOI: 10.1371/journal.pone.0279895]
- Song P L, Liu X Z, Sun L, Zhai X C, Wang J, He L, Wang Y Y, Zhang Y Q and Li G C. 2024. Soil moisture estimation based on FY-3E backscattering data for enhanced daily coverage to SMAP observations in the dawn-dusk orbit. *Remote Sensing of Environment*, 309: 114209 [DOI: 10.1016/j.rse.2024.114209]
- Song P L, Zhang Y Q, Guo J P, Shi J C, Zhao T J and Tong B. 2022. A 1 km daily surface soil moisture dataset of enhanced coverage under all-weather conditions over China in 2003-2019. *Earth System Science Data*, 14(6): 2613-2637 [DOI: 10.5194/essd-14-2613-2022]
- Sørensen R, Zinko U and Seibert J. 2006. On the calculation of the topographic wetness index: evaluation of different methods based on field observations. *Hydrology and Earth System Sciences*, 10(1): 101-112 [DOI: 10.5194/hess-10-101-2006]
- Srivastava P K, Han D W, Ramirez M R and Islam T. 2013. Machine learning techniques for downscaling SMOS satellite soil moisture using MODIS land surface temperature for hydrological application. *Water Resources Management*, 27(8): 3127-3144 [DOI: 10.1007/s11269-013-0337-9]
- Sun H, Zhang X H and Zhao X. 2022. Series or parallel? An exploration in coupling physical model and machine learning method for disaggregating satellite microwave soil moisture. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 4415015 [DOI: 10.1109/TGRS.2022.3216343]
- Tarolli P. 2015. Holocene book review: digital terrain analysis in soil science and geology. *The Holocene*, 25(6): 1048-1049 [DOI: 10.1177/0959683615572731]
- Tehrany M S, Pradhan B and Jebur M N. 2014. Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. *Journal of Hydrology*, 512: 332-343 [DOI: 10.1016/j.jhydrol.2014.03.008]
- Vinnikov K Y, Robock A, Speranskaya N A and Schlosser C A. 1996. Scales of temporal and spatial variability of midlatitude soil moisture. *Journal of Geophysical Research: Atmospheres*, 101(D3): 7163-7174 [DOI: 10.1029/95JD02753]
- Wang H L, Han G Z and Xie X J. 2016. Scale effect analysis to topographic wetness index extracted by single flow direction algorithm in different terrain area. *Geography and Geo-Information Science*, 32(4): 23-29 (王海力, 韩光中, 谢贤建. 2016. 单流向法

- 地形湿度指数尺度效应的不同地形区差异分析. 地理与地理信息科学, 32(4): 23-29 [DOI: 10.3969/j.issn.1672-0504.2016.04.005]
- Wang J, Zhang Y Q, Song P L and Tian J. 2024. Estimating sub-daily resolution soil moisture using Fengyun satellite data and machine learning. *Journal of Hydrology*, 632: 130814 [DOI: 10.1016/j.jhydrol.2024.130814]
- Wang S C, Cai Y L, Zhu Z Z, Huang X D and Zhao X W. 2024. Downscaling SMAP soil moisture using a combination of XGBoost and DSCGAN algorithms. *Journal of Geo-Information Science*, 26(9): 2213-2225 (王思超, 蔡玉林, 朱子正, 黄修东, 赵相伟. 2024. XGBoost和DSCGAN模型协同的SMAP土壤水分降尺度方法. 地球信息科学学报, 26(9): 2213-2225) [DOI: 10.12082/dqxkx.2024.240152]
- Wang X Z, Zhang Q K, Huang Y X and Ji J T. 2022. An efficient method for determining DEM parameters of a loose cohesive soil modelled using hysteretic spring and linear cohesion contact models. *Biosystems Engineering*, 215: 283-294 [DOI: 10.1016/j.biosystemseng.2022.01.015]
- Wang Y Z, Wang W, Huang J Z, Jing K and Zhou K L. 2023. A methodological study of downscaling of ERA5 temperature using terrain height difference. *Journal of Meteorological Research and Application*, 44(2): 33-38 (王乙竹, 王玮, 黄剑钊, 景坤, 周坤论. 2023. 利用地形高度差对ERA5气温降尺度的方法研究. 气象研究与应用, 44(2): 33-38) [DOI: 10.19849/j.cnki.CN45-1356/P.2023.2.06]
- Wen F P, Zhao W, Hu L, Xu H X and Cui Q. 2021. SMAP passive microwave soil moisture spatial downscaling based on optical remote sensing data: a case study in Shandian river basin. *National Remote Sensing Bulletin*, 25(4): 962-973 (文凤平, 赵伟, 胡路, 徐红新, 崔倩. 2021. 耦合MODIS数据的SMAP被动微波土壤水分空间降尺度研究——以闪电河流域为例. 遥感学报, 25(4): 962-973) [DOI: 10.11834/jrs.20219393]
- Wen Y Y, Zhao J, Zhu G F, Xu R and Yang J X. 2021. Evaluation of the RF-based downscaled SMAP and SMOS products using multi-source data over an Alpine Mountains Basin, Northwest China. *Water*, 13(20): 2875 [DOI: 10.3390/w13202875]
- Wu D D, Di C L, Wang T J, Wang L C and Chen X. 2021. Characterization of the coherence between soil moisture and precipitation at regional scales. *Journal of Geophysical Research: Atmospheres*, 126(8): e2020JD034340 [DOI: 10.1029/2020JD034340]
- Wu P, Feng Y Q, Liang S H, Wu Q B and Wan L. 2016. Estimating soil moisture based on TVDI and GLDAS using downscaling method. *Journal of Beijing Normal University (Natural Science)*, 52(3): 265-270 (吴盼, 冯雨晴, 梁四海, 吴青柏, 万力. 2016. 基于GLDAS与TVDI降尺度反演土壤含水量. 北京师范大学学报(自然科学版), 52(3): 265-270) [DOI: 10.16360/j.cnki.jbnuns.2016.03.003]
- Xu W, Zhang Z X, Long Z H and Qin Q M. 2021a. Downscaling SMAP soil moisture products with convolutional neural network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 4051-4062 [DOI: 10.1109/JSTARS.2021.3069774]
- Xu Z G, Wu Z Y, He H, Guo X and Zhang Y L. 2021b. Comparison of soil moisture at different depths for drought monitoring based on improved soil moisture anomaly percentage index. *Water Science and Engineering*, 14(3): 171-183 [DOI: 10.1016/j.wse.2021.08.008]
- Xu Z H, Sun H, Gao J H, Wang Y J, Wu D, Zhang T and Xu H Y. 2024. PhySoilNet: a deep learning downscaling model for microwave satellite soil moisture with physical rule constraint. *International Journal of Applied Earth Observation and Geoinformation*, 135: 104290 [DOI: 10.1016/j.jag.2024.104290]
- Yang H B, Cui X, Cai Y C, Wu Z R, Gao S Q, Yu B, Wang Y L, Li K, Duan Z and Liang Q H. 2024. Coupling downscaling and calibrating methods for generating high-quality precipitation data with multisource satellite data in the Yellow River Basin. *Remote Sensing*, 16(8): 1318 [DOI: 10.3390/rs16081318]
- Yang Q F, Zhang P Y, Li J, Liu W X and He X L. 2022. Development level and spatio-temporal evolution of agricultural modernization in northeast China. *Scientia Geographica Sinica*, 42(9): 1588-1599 (杨奇峰, 张平宇, 李静, 刘文新, 何秀丽. 2022. 东北地区农业现代化发展水平测度与时空演变分析. 地理科学, 42(9): 1588-1599) [DOI: 10.13249/j.cnki.sgs.2022.09.008]
- Yang Y, Dou Y X, Liu D and An S S. 2017. Spatial pattern and heterogeneity of soil moisture along a transect in a small catchment on the Loess Plateau. *Journal of Hydrology*, 550: 466-477 [DOI: 10.1016/j.jhydrol.2017.05.026]
- Yilmaz I. 2009. Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: a case study from Kat landslides (Tokat—Turkey). *Computers and Geosciences*, 35(6): 1125-1138 [DOI: 10.1016/j.cageo.2008.08.007]
- Zhang C X, Yang Q K and Li R. 2005. Advancement in topographic wetness index and its application. *Progress in Geography*, 24(6): 116-123 (张彩霞, 杨勤科, 李锐. 2005. 基于DEM的地形湿度指数及其应用研究进展. 地理科学进展, 24(6): 116-123) [DOI: 10.3969/j.issn.1007-6301.2005.06.014]
- Zhang J X, Liu K and Wang M. 2021a. Downscaling groundwater storage data in China to a 1-km resolution using machine learning methods. *Remote Sensing*, 13(3): 523 [DOI: 10.3390/rs13030523]
- Zhang M, Ge Y and Wang J H. 2024. Optimized soil moisture mapping strategies on the Tibetan Plateau using downscaled and interpolated maps as mutual covariates. *Remote Sensing*, 16(21): 3939 [DOI: 10.3390/rs16213939]
- Zhang R Q, Li L, Zhang Y, Huang F N, Li J D, Liu W, Mao T N, Xiong Z L and Shangguan W. 2021b. Assessment of agricultural drought using soil water deficit index based on ERA5-Land soil moisture data in four southern provinces of China. *Agriculture*, 11(5): 411 [DOI: 10.3390/agriculture11050411]
- Zhang Y G, Nearing M A, Zhang X C, Xie Y and Wei H. 2010. Projected rainfall erosivity changes under climate change from multi-model and multiszenario projections in Northeast China. *Journal of Hydrology*, 384(1/2): 97-106 [DOI: 10.1016/j.jhydrol.2010.01.013]

- Zhang Z X, Xu W, Qin Q M and Long Z H. 2021c. Downscaling solar-induced chlorophyll fluorescence based on convolutional neural network method to monitor agricultural drought. *IEEE Transactions on Geoscience and Remote Sensing*, 59(2): 1012-1028 [DOI: 10.1109/TGRS.2020.2999371]
- Zhao T J. 2018. Recent advances of L-band application in the passive microwave remote sensing of soil moisture and its prospects. *Progress in Geography*, 37(2): 198-213 (赵天杰. 2018. 被动微波反演土壤水分的L波段新发展及未来展望. *地理科学进展*, 37(2): 198-213) [DOI: 10.18306/dlkxjz.2018.02.003]
- Zhao W S and Zhou Y H. 1977. Neutron measurement of soil moisture. *Soils*, (2): 110-115 (赵渭生, 周月华. 1977. 土壤水分的中子测量法. *土壤*, (2): 110-115) [DOI: 10.13758/j.cnki.tr.1977.02.002]
- Zhou Z, Zhao S J and Jiang L M. 2016. Downscaling methods of passive microwave remote sensing of soil moisture. *Journal of Beijing Normal University (Natural Science)*, 52(4): 479-485 (周壮, 赵少杰, 蒋玲梅. 2016. 被动微波遥感土壤水分产品降尺度方法研究综述. *北京师范大学学报(自然科学版)*, 52(4): 479-485) [DOI: 10.16360/j.cnki.jbnuns.2016.04.013]
- Zhu W Z, You D Q, Wen J G, Liu Q and Tang Y. 2023. Evaluating the performance of MODIS Albedo Products (MCD43A3) over seasonal snow-covered land surface. *Remote Sensing Technology and Application*, 38(6): 1295-1305 (朱文哲, 游冬琴, 闻建光, 刘强, 唐勇. 2023. MCD43A3 积雪地表遥感反照率产品精度分析与评价. *遥感技术与应用*, 38(6): 1295-1305) [DOI: 10.11873/j.issn.1004-0323.2023.6.1295]

Multiproduct collaborative downscaling of soil moisture in Northeast China considering terrain convergence effects

XIAO Jing^{1,2}, LI Qiangzi^{1,2}, ZHANG Yuan^{1,2}, WANG Hongyan^{1,2}, DU Xin^{1,2},
XU Jingyuan^{1,2}, DONG Yong^{1,2}

1. National Engineering Research Center of Satellite Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100094, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: Soil moisture is a pivotal variable within the terrestrial hydrological cycle, exerting a critical influence on climate change, agricultural productivity, and ecosystem management. Accurate, high-resolution soil moisture data is essential for applications such as drought monitoring, flood prediction, agricultural precision irrigation, and the refinement of climate and carbon cycle models. However, prevailing soil moisture downscaling methodologies are constrained by significant limitations. This limitations include reliance on single-source soil moisture data products, which fail to leverage the complementary information from observations and models of different scales and physical mechanisms. Furthermore, the selection of predictive covariates is often incomplete, frequently overlooking key hydrological drivers such as terrain-controlled convergence effects, which govern the spatial distribution of moisture. This study addresses these gaps by proposing an integrated downscaling framework. The primary objective is to generate high-resolution, spatiotemporally continuous daily soil moisture data for Northeast China, thereby enhancing the precision and applicability of fine-scale soil moisture monitoring for ecological, hydrological, and agricultural management.

This research was conducted in Northeast China, a region characterized by a semihumid continental climate, rolling topography, and significant importance as a national grain production base. The core methodology involved a synergistic downscaling model that incorporated multisource soil moisture products and key terrain convergence features. The model inputs were as follows: (1) Three soil moisture products based on different principles and scales—GLDAS (model assimilation, 25 km), SMAP (satellite passive microwave, 9 km), and ERA5_Land (reanalysis assimilation, ~8 km); (2) A comprehensive suite of covariates encompassing meteorological data (precipitation, air temperature), direct land surface parameters (albedo, evapotranspiration), vegetation indices (NDVI, EVI, NDWI), topographic attributes (elevation, slope, aspect), and, specifically, terrain convergence indices [stream power index (SPI) and topographic wetness index (TWI)] calculated from SRTM DEM; and (3) Soil texture data (sand, silt, clay). All data were harmonized to a 1 km spatial resolution and a daily temporal scale for the period 2019—2023. Four representative machine learning algorithms—random forest (RF), light gradient-boosting machine (LightGBM), deep feedforward neural network (DFNN), and convolutional neural network (CNN)—were employed and comparatively evaluated to construct the downscaling models. Eleven controlled experiments were designed to assess the individual and combined contributions of the multisource soil moisture products and the terrain convergence factors. Model training and validation utilized in-situ soil moisture measurements from 229 stations, with data partitioned into training (190 stations) and validation (39 stations) sets. Model performance was rigorously evaluated using the coefficient of determination (R^2), root-mean-square error (RMSE), and Bias.

Experimental results demonstrated that the proposed framework successfully enhanced downscaling accuracy. The integration of the three complementary soil moisture products (ERA5-Land, SMAP, and GLDAS) yielded superior performance compared with any single product or dual-product combination, with the best model achieving an R^2 of 0.849, RMSE of 0.095, and Bias of 0.003. Among the machine learning algorithms, LightGBM consistently delivered the highest accuracy. The introduction of terrain convergence factors, particularly the

combined use of SPI and TWI, significantly improved the model's ability to fit the spatial distribution of soil moisture, raising the R^2 from 0.843 (without convergence factors) to 0.849. Feature importance analysis confirmed the dominant role of the input soil moisture products, followed by the terrain and hydrological covariates (SPI, TWI, slope aspect). The generated 1 km daily soil moisture product effectively captured fine-scale spatial heterogeneity and seasonal dynamics, showing a high median correlation ($r = 0.925$) with in-situ validation data, which outperformed the original coarse-resolution products (ERA5_Land: $r=0.786$, SMAP: $r=0.691$, GLDAS: $r=0.622$). Spatial details in low-, medium-, and high-moisture zones were refined, and temporal series trends aligned closely with station observations. A comparative analysis with other recent downscaling studies confirmed the competitive performance of the proposed method.

This study developed an effective soil moisture downscaling approach for Northeast China that successfully addresses the limitations of single-data-source dependency and incomplete covariate selection. By synergistically integrating multiscale soil moisture products (ERA5_Land, SMAP, GLDAS) and explicitly incorporating terrain convergence effects (via SPI and TWI), the method generated a high-resolution (1 km) daily soil moisture dataset with improved accuracy and spatiotemporal consistency. The LightGBM algorithm was identified as the most effective model for this task. The results confirm that multisource data integration provides complementary information, and terrain convergence features are crucial for capturing the spatial patterns of soil moisture governed by hydrological processes. The final downscaled product reliably reflects observed soil moisture variations, offering valuable support for fine-scale applications in agricultural water management, hydrological modeling, and ecological monitoring. Future work could focus on enhancing the model's adaptability to diverse global climates and topographies and incorporating broader temporal data to capture extreme hydrological events.

Key words: soil moisture downscaling, Northeast China, multi-source data, machine learning, deep learning, terrain convergence, spatiotemporal continuity, soil moisture products

Supported by National Key Research and Development Program of China (No. 2021YFD1500103); Strategic Priority Research Program of the Chinese Academy of Sciences (No. XDA28070504); Key Program of High-resolution Earth Observation System (No. 71-Y50G10-9001-22/23)