

多源驱动与季节性集成学习的 SMAP 表层土壤水分降尺度方法

张春芳¹, 朱胜民², 潘登³, 孟文民¹, 于海洋²

(1.河南省焦作水文水资源测报分中心,河南 焦作 475008;2.河南理工大学 自然资源部矿山时空信息与生态修复重点实验室,河南 焦作 454000;3.河南省自然资源监测和国土整治院,郑州 450199)

摘要:针对土壤水分主动被动卫星(soil moisture active passive, SMAP)土壤水分产品空间分辨率较粗、难以满足区域精细化应用需求的问题,本文以河南省为研究区,提出一种多源驱动与季节性集成学习相结合的 1 km 日尺度表层土壤水分(surface soil moisture, SSM)降尺度方法.以 SMAP L4 SSM 为目标变量,融合遥感植被与能量因子、气象降水因子、土壤属性及地形因子,采用“9 km 训练-1 km 推理”策略,构建基于 Top- k 优选与 Stacking 的季节性集成模型 SOBLE-Top5.结果表明,分季节建模整体优于全年统一建模;SOBLE-Top5 在春、夏、秋、冬测试集上的 R^2 分别为 0.938 9、0.907 8、0.897 7 和 0.963 2,均方根误差(RMSE)分别为 0.020 8、0.029 1、0.022 2 和 0.013 3 m^3/m^3 .站点验证表明,降尺度结果能够较好表征不同地类下 SSM 时序变化.SHAP 分析显示,SSM 驱动机制具有明显季节差异,整体呈现“冷季土壤属性主导、暖季多因子协同驱动”的特征.研究可为区域农业干旱监测和水资源管理提供高分辨率土壤水分数据支持.

关键词: SMAP; 表层土壤水分; 降尺度; 季节性建模; 集成学习

中图分类号: P237

文献标志码: A

文章编号: 1000-2367(2026)05-0062-10

表层土壤水分(surface soil moisture, SSM)是表征陆地水循环、能量交换和农业干旱状况的重要变量,对作物生长监测、灌溉调度、干旱识别和水资源管理具有重要意义^[1-2].随着微波遥感技术的发展,土壤水分主动被动卫星(SMAP)产品因其较强的土壤水分敏感性、较高的时间连续性和全球覆盖能力,已成为区域和全球尺度土壤水分监测的重要数据源^[3-6].然而,SMAP 土壤水分产品空间分辨率相对较粗,难以满足农业旱情识别、县域水资源管理和地表异质性分析等精细化应用需求,因此有必要开展高分辨率降尺度研究^[4-5].

国内外学者围绕卫星土壤水分降尺度开展了大量研究,主要形成了物理机制驱动、统计经验建模和机器学习建模等方法体系^[4-7].现有研究总体可归纳为物理/半物理方法、统计经验方法和机器学习(含深度学习)方法三大类.物理或半物理方法强调能量平衡、植被/土壤辐射传输或散射机理约束,具有较好的物理可解释性,但对参数、先验条件和场景适用性要求较高;统计经验方法实现相对简洁,适用于特定区域快速建模,但跨时空泛化能力常受限制;机器学习方法则能够利用光学、热红外、地形、气象与陆面参数等多源协变量刻画复杂非线性关系,在精度与空间细节恢复方面展现出明显优势^[8-12].近年来的系统综述进一步指出,学习型方法与多源融合已成为土壤水分遥感估计的重要趋势,但同时也面临植被干扰、观测深度差异、样本代表性不足和模型可迁移性不稳定等问题^[13-14].

收稿日期: 2026-03-11; **修回日期:** 2026-05-27.

基金项目: 国家自然科学基金(U1304402, 41977284); 河南省水利科技攻关项目(GG202412); 河南省自然资源科研项目(2019-379-16).

作者简介: 张春芳(1974—),男,河南焦作人,河南省焦作水文水资源测报分中心高级工程师,主要从事水文水资源研究, E-mail: 184140595@qq.com.

通信作者: 朱胜民, E-mail: 212304020095@home.hpu.edu.cn.

引用本文: 张春芳, 朱胜民, 潘登, 等. 多源驱动与季节性集成学习的 SMAP 表层土壤水分降尺度方法[J]. 河南师范大学学报(自然科学版), 2026, 54(5): 62-71. (Zhang Chunfang, Zhu Shengmin, Pan Deng, et al. Downscaling SMAP surface soil moisture using multi-source drivers and seasonal ensemble learning[J]. Journal of Henan Normal University(Natural Science Edition), 2026, 54(5): 62-71. DOI: 10.16366/j.cnki.1000-2367.2026.03.11.0001.)

近年来,随着机器学习方法的发展,越来越多研究将随机森林、深度学习以及集成学习策略应用于卫星土壤水分降尺度,以提升 SMAP 等产品的空间分辨率和预测精度^[15]。此外,一些研究通过融合多源遥感数据或引入时空信息进一步改进降尺度方法^[16-17]。针对机器学习降尺度中“单模型性能波动大、全年统一建模难以适应季节差异”的问题,集成学习方法近年来在遥感反演与环境变量建模中得到广泛应用。该类方法通过构建多个基学习器并对其预测结果进行组合,以提升模型的预测精度与泛化能力。然而,现有研究仍普遍存在三方面不足:其一,全年统一映射关系往往弱化了不同季节降水-植被-能量过程对 SSM 的差异化控制,导致模型在季节转换期或极端气象背景下稳定性下降;其二,集成学习框架虽能提高精度,但部分研究对基学习器筛选逻辑、季节适配策略与泛化边界讨论不足;其三,模型解释多停留在变量重要性排序层面,对多源驱动因素的季节主导机制和非线性作用缺乏更细致阐释。

基于上述问题,本文以河南省为研究区,提出一种多源驱动与季节性集成学习相结合的 SMAP 表层土壤水分降尺度方法。研究以 SMAP L4 SSM 产品为目标变量,融合遥感植被与能量因子、气象降水因子、土壤属性和地形因子,采用“9 km 训练-1 km 推理”的降尺度策略;在此基础上,按照冬、春、夏、秋构建分季节模型,并引入基于 Top-*k* 优选与 Stacking 的季节性集成学习框架 SOBLE-Top5(stacking optimal basic learner ensemble Top 5),进一步结合 SHAP(shapley additive explanations)方法分析不同季节下主导驱动因子的贡献差异与作用机制。

1 研究区与数据

1.1 研究区概况

河南省(31°23′~36°22′N,110°21′~116°39′E)位于华北平原南部,面积约 16.7 万 km²,是我国重要农业产区。研究区域(附录图 S1)形总体呈“西高东低”格局,西部以山地丘陵为主,中东部为黄淮海平原,地形起伏和下垫面差异明显,对表层土壤水分(SSM)的空间分布具有重要影响。该区属暖温带-北亚热带过渡型季风气候,年均气温约 12~16 °C,年降水量约 500~900 mm,雨热同期特征显著,土壤水分形成与消耗过程具有明显季节差异。河南省耕地广泛分布,小麦、玉米等粮食作物种植面积大,灌溉和耕作活动频繁,不同季节植被覆盖和地表水热状态变化明显。因此,2023 年 12 月至 2024 年 11 月在该区域开展多源数据驱动的 SMAP SSM 降尺度研究,对省域农业干旱监测和土壤水分精细化表征具有重要意义。

1.2 数据来源

1.2.1 SMAP 土壤水分数据

SMAP 任务是 L 波段微波土壤水分观测的重要平台,具备较好的物理反演基础与全球连续观测能力。采用 SMAP L4 级全球 3 h、9 km 表层与根区土壤水分产品(SPL4SMGP)作为目标数据源,使用其中表层土壤水分变量进行建模。考虑到本研究以日尺度分析为主,为保证与日尺度遥感/气象因子一致,需将原始 3 h 产品进行时间聚合(如日均值或按研究设计确定的日尺度统计量),生成连续逐日表层土壤水分(SSM)序列。

1.2.2 遥感驱动因子数据

遥感驱动因子主要来自中分辨率成像光谱仪(MODIS)及高分辨率土地覆盖产品,用于表征地表植被、水热状态和下垫面类型差异。选取 MOD09GA、MCD43A3、MCD15A3H 及 Dynamic World V1 等数据源,并通过 Google Earth Engine(GEE)平台获取研究期内数据。

1)MOD09GA 地表反射率:提供多波段大气校正地表反射率,可用于计算归一化植被指数(normalized difference vegetation index,NDVI)、增强型植被指数(enhanced vegetation index,EVI)、归一化水体指数(normalized difference water index,NDWI)、归一化多波段干旱指数(normalized multi-band drought index,NMDI)等指数,以刻画植被生长和地表含水状态变化。基于 QC 筛选高质量像元,并对缺失像元进行时间插值,以降低云污染与观测缺失影响。相关计算公式见附录表 S1。

2)MCD43A3 BRDF/Albedo 产品:基于双向反射分布函数(BRDF)建模生成逐日反照率,获得可见光波段反射率(Albedo-VIS)和近红外波段反射率(Albedo-NIR)变量,用于反映地表辐射特性及其与水热过程的耦合关系。

3)MCD15A3H LAI/FPAR 产品;用于获取叶面积指数(leaf area index, LAI),补充植被覆盖对土壤水分蒸散与遮蔽效应的表征.针对 LAI 产品进行像元级质量筛查与时间插值重以增强可复现性.

4)Dynamic World V1 土地覆盖数据;提供近实时 10 m 地表覆盖类型信息,可作为土地覆盖类型(land cover, LC)辅助因子,刻画不同下垫面情景下 SSM 响应差异.在建模中建议说明其作为分类变量或概率型变量的处理方式,避免审稿人质疑类别变量重采样引入偏差.

1.2.3 气象与降水数据

气象因子用于表征 SSM 的短时驱动与季节性背景约束,其中地表温度与降水是核心的变量之一.采用 MOD11A1 V6.1 日尺度 1 km 地表温度(land surface temperature, LST)以及日尺度降水数据.其中,MOD11A1 数据采用了质量控制(QC=0)筛选,并结合滑动时间窗与空间高斯滤波进行噪声抑制与局部缺失修补.降水量(precipitation, Prec)数据采用 CHIRPS v2.0(0.05°, 日尺度),该数据融合卫星估计与站点观测,在农业与水文应用中具有较高可用性.以与 SMAP 匹配的“当日降水”作为基线预测变量.

1.2.4 土壤属性与地形辅助数据

土壤属性与地形因子主要用于刻画 SSM 的静态空间约束,弥补遥感与气象变量对地表结构信息表征不足的问题.采用 HWSO 土壤数据库提取表层土壤中砂含量(Sand)、粉砂含量(Silt)、黏土含量(Clay)土壤容重(bulk density, BD)等变量,并采用 NASADEM/SRTM 派生坡度(Slope)、坡向(Aspect)、高程(Elevation)以及地形湿度指数(topographic wetness index, TWI)等地形因子.其中, TWI 基于坡度与汇流累积面积计算,是表征地形汇水倾向和潜在湿润程度的经典指标.计算公式见附录表 S1(5)和(6).

1.2.5 地面站点土壤水分观测数据

地面站点观测数据由焦作水文局提供,共 322 个监测站点,观测深度包括 10 cm、20 cm、40 cm,每日多次(0:00、4:00、8:00、12:00、16:00、20:00)采集.为匹配本文日尺度研究目标,对站点观测进行了质量控制(剔除异常值与统计离群值)并进行日尺度聚合,最终采用 10 cm 深度日均值参与验证.需要指出的是, SMA-PL4 表层土壤水分代表深度与地面 10 cm 观测层存在深度差异,这可能带来一定验证不确定性,但相邻浅层土壤水分通常具有较强相关性,因此该验证方案在区域尺度研究中具有可接受性^[18].

1.3 数据预处理与样本构建

为保证 SMAP L4 SSM 与多源驱动因子的尺度一致性,本文采用“9 km 训练-1 km 推理”的样本构建策略.首先,对 10、30 和 500 m 等高/中分辨率数据进行空间聚合,对降水数据采用双线性插值重采样,形成统一的 1 km 驱动因子数据集;随后将其聚合至 9 km 尺度,并与逐日 SMAP L4 SSM 匹配构建监督学习样本.在推理阶段,将训练完成的季节性模型应用于 1 km 驱动因子栅格,生成 1 km 日尺度 SSM 降尺度结果.该策略能够避免粗分辨率目标变量与高分辨率驱动因子直接配对引起的尺度失配,同时保留高分辨率空间细节.

针对多源遥感和气象数据中云污染、缺失值和异常像元等问题,本文对 MOD09GA、LAI、LST 等变量进行质量筛选,并采用时间插值、平滑处理及高斯滤波等方法进行修补和降噪.为刻画季节性差异,按照气象学季节将样本划分为冬季(12-次年 2 月)、春季(3-5 月)、夏季(6-8 月)和秋季(9-11 月),各季节分别构建独立样本集,并在 9 km 尺度下按 70%和 30%划分训练集与测试集.训练、测试和推理阶段保持变量名称、单位和标准化规则一致,标准化参数仅由训练集计算,以避免信息泄露;最终将各季节 1 km 推理结果按时间顺序拼接,形成全年 1 km SSM 产品.

2 方法

2.1 总体降尺度框架

本文总体降尺度流程见附录图 S2.首先,对遥感、气象、土壤属性和地形辅助数据进行质量控制、缺失值填补、因子计算和空间重采样,生成多源预测因子.训练阶段,将预测因子统一聚合至 9 km 分辨率,并与 SMAP L4 SSM 配对构建样本;随后按冬、春、夏、秋分别建模,各季节样本按 70%和 30%划分训练集与测试集.基于训练集训练多个候选基学习器,并通过五折交叉验证筛选表现较优的模型,构建 Top-*k* 组合与 Stacking 集成模型.推理阶段,将训练好的季节性集成模型应用于 1 km 预测因子栅格,生成研究区 1 km 日尺度

SSM 降尺度结果,最终形成四季及全年连续的 1 km SSM 产品,用于精度评价、时空分析和驱动机制解释。

2.2 季节性建模策略

在区域尺度 SSM 降尺度中,若采用全年统一建模,通常默认全年样本共享相对稳定的输入-输出映射关系。然而,河南省受季风气候影响明显,降水输入、蒸散过程、植被生长状态及农业管理活动均具有显著季节差异,导致多源驱动因子分布及其与 SSM 的响应关系随季节发生变化。全年样本直接混合训练虽可扩大样本量,但可能弱化不同季节下土壤水分形成与消耗机制的差异,尤其在春季回暖、汛期前后和秋季收获等阶段更易产生预测偏差。因此,本文采用分季节建模策略,按照气象学季节将研究期划分为冬季(12-2 月)、春季(3-5 月)、夏季(6-8 月)和秋季(9-11 月)。该划分方式规则明确、便于复现,并与日尺度样本组织和跨季节比较相一致。各季节分别构建独立样本集,并在季节内部进行模型训练、验证和推理。各季节训练集与测试集样本数量见附录表 S2。

2.3 基学习器构建与优选

2.3.1 候选基学习器设置

为兼顾非线性拟合能力、模型多样性与计算效率,本文构建两类候选模型体系:一类为用于基准对比的代表性模型(如 DNN、GBM、DRF),另一类为用于异质集成的候选基学习器集合(如 RF、ET、XGBoost、CatBoost、KNN、LightGBM)。其中,DNN 用于表征多源驱动因子与 SSM 之间潜在的复杂非线性关系,模型由 3 层隐含层(128-64-32)构成,通过全连接结构和非线性激活函数自动提取多层次抽象特征,并配合 Adam 优化算法与正则化约束;GBM 模型参数设置为 100 棵决策树,单棵树最大深度 10,学习率 0.1,并通过五折交叉验证进行稳健性评估。DRF 通过构建多个决策树,训练样本基于行(Bootstrap 采样)和特征列(随机特征子集)的双重随机性构建。RF、ET、XGBoost、CatBoost、LightGBM 等树模型适合处理异质尺度、多源变量和非线性交互问题,且对变量尺度与分布假设要求较弱。KNN 可作为局部相似性驱动的非参数参考模型,用于提供与树模型差异化的误差结构。通过保留算法机制差异,可增强后续集成阶段的误差互补潜力。

2.3.2 基学习器性能筛选与优选依据

基学习器优选应建立在可量化指标基础上,而非经验选取。本文采用“测试集 RMSE(root mean square error)优先、 R^2 约束校核”的综合标准进行排序,并结合五折交叉验证均值结果与离散程度评价模型稳定性。对于季节性集成阶段,可从候选模型中选取前 k 个($k=2,3,4,5$)基学习器进入组合试验,以便比较不同组合规模的收益与冗余效应。

2.4 季节性集成学习方法

2.4.1 集成学习框架设计思路

单一模型在异质地表条件下容易受样本分布、参数设置和模型假设影响,表现出季节性性能波动。集成学习通过组合多个具有差异性的基学习器,可在偏差与方差之间取得更优平衡,从而提升预测稳健性和泛化能力。针对本研究季节性特征,本文采用“分季节建模+季节内异质集成”的双层策略,即先在季节维度上降低样本机制异质性,再在模型维度上利用不同算法的误差互补性。

2.4.2 基学习器组合策略与 Top- k 优选机制

为避免直接固定单一组合规模,本文采用 Top- k 组合机制,即依据季节内基学习器性能排序结果,分别构建 Top-2、Top-3、Top-4、Top-5 组合方案,并比较不同 k 值下的集成表现。该设计既能评估“增加模型数量”带来的收益,也能检验冗余基学习器对集成性能的潜在稀释作用。

2.4.3 堆叠集成学习模型构建

季节性 stacking 集成模型的实现流程如下:

1)模型训练与集成学习流程基于 PyCaret 平台实现。首先,将原始样本随机划分为训练集和测试集,比例分别为 70%和 30%。为避免不同量纲变量对模型训练产生影响,所有输入特征均采用训练集统计量进行 z-score 标准化,并将相同转换规则应用于交叉验证、测试和推理阶段,以防止信息泄露。

2)在 Stacking 集成过程中,首先训练 M 个基学习器,并通过五折交叉验证生成折外预测(out-of-fold prediction, OOF)。随后,将各基学习器的 OOF 预测组合形成元特征矩阵 FM,用于训练元学习器 M_0 。测试阶段,各基学习器在完整训练集上重新训练,并对测试集生成预测结果 Test1, Test2, ..., TestM,再由元学习器

M0 融合得到最终预测值.

3)元学习器根据不同季节下基学习器的交叉验证表现确定,其中 ET 在冬季、夏季和秋季表现最优,RF 在春季表现最优.由于 OOF 预测对应同一目标变量 SSM,具有一致单位和可比量级,且元学习器为树模型,对线性尺度变换不敏感,因此未对 OOF 预测进行额外标准化处理.

2.5 模型精度评价

为综合评价模型性能,本文采用相关系数(R)、决定系数(R^2)、均方根误差($RMSE$)、平均绝对误差(mean absolute error, MAE)和偏差($Bias$)等指标.其中, R 与 R^2 用于衡量拟合一致性与解释度, $RMSE$ 与 MAE 用于表征误差幅度, $Bias$ 用于反映系统性高估或低估倾向,相关计算公式见附录表 S1(7)~(10).

2.6 模型解释方法

为解释季节性集成模型在不同季节下的驱动因子贡献差异,引入 SHAP^[19] 方法.SHAP 基于合作博弈论中的 Shapley 值,将模型预测分解为各输入特征对预测结果的边际贡献,具有局部解释与全局汇总兼容、可比较性强等优点.对于树模型及其集成模型,SHAP 已被广泛用于环境遥感、水文气象与地学机器学习解释分析,可较好揭示非线性模型的关键驱动因子及其方向性作用.本研究采用 SHAP 的主要原因在于:一方面,季节性集成模型包含多个非线性基学习器与元学习器,传统线性回归系数难以直接反映变量贡献;另一方面,本文关注的不仅是“总体重要性排序”,还包括“季节间主导因子变化”,而 SHAP 在跨模型、跨季节比较方面具有较好的统一量纲解释能力.

3 降尺度结果与精度验证

3.1 季节性建模与全季节建模对比结果

本研究分析表明分季节建模整体优于全年统一建模(附录表 S3),说明不同季节下 SSM 与环境因子的响应关系存在明显差异.春季 RF 模型较全年统一模型 $RMSE$ 降低约 12.3%, R^2 提升约 4.4%;冬季提升最为明显,ET 和 RF 模型的 R^2 分别达到 0.949 3 和 0.947 9, $RMSE$ 较全年统一建模降低约 47%~50%.夏季和秋季模型增益具有一定模型依赖性,其中夏季 ET 模型 R^2 为 0.872 7,秋季 ET 模型 R^2 为 0.864 7.整体来看,ET、RF 等树模型表现较稳定,而 LightGBM 精度相对较低.结果说明,分季节建模能够有效增强模型对季节性水热过程的适应能力,也为后续引入集成学习提供了依据.

3.2 季节性集成学习方法性能评估

3.2.1 不同集成方式模型性能比较

对不同 Top- k 组合与不同集成策略(Blender、Stacking)的比较表明,采用“最优基学习器作为元学习器”的 Stacking 策略在 Top-5 组合下整体效果最佳(附录表 S4),即 SOBLE-Top5.与季节内最优单一基学习器相比,该策略在春、夏、秋、冬四季 R^2 分别提升 4.65%、3.06%、2.85%和 0.98%, $RMSE$ 分别降低 21.22%、11.14%、9.30%和 9.55%.这一结果表明,SOBLE-Top5 能够通过模型互补和误差抵消,在不同季节下稳定地获得净增益.相比之下,线性回归型 Stacking 在春夏季有一定提升,但在秋冬季出现性能波动;Blender 策略整体未达到理想效果,部分情形下甚至低于季节内最优单模型.

3.2.2 集成模型与单模型性能比较

测试集结果表明,SOBLE-Top5 在 4 个季节均保持最优性能,体现出良好的泛化能力(附录表 S5).其在春、夏、秋、冬季测试集上的 R^2 分别达到 0.938 9、0.907 8、0.897 7 和 0.963 2, $RMSE$ 分别为 0.020 8、0.029 1、0.022 2 和 0.013 3 m^3/m^3 , MAE 分别为 0.015 1、0.021 7、0.016 7 和 0.009 7 m^3/m^3 ;平均测试集 R^2 约为 0.93.冬季表现最优($R^2=0.963\ 2$, $RMSE=0.013\ 3$, $MAE=0.009\ 7$),说明该季节下模型与 SMAP L4 SSM 的一致性较高,误差较低.与单模型相比,SOBLE-Top5 对 DNN 的提升尤为明显.基于测试集结果,SOBLE-Top5 相较 DNN 在四季的 R^2 分别提升 11.96%、24.53%、20.19%和 12.58%, $RMSE$ 分别降低 38.28%、41.57%、36.39%和 49.62%, MAE 分别降低 41.92%、44.07%、40.00%和 51.50%.其中,夏季 R^2 提升幅度最大,而冬季 $RMSE$ 与 MAE 降幅最大,说明集成策略在不同季节的增益表现具有差异化特征.

在季节性建模基础上构建的 SOBLE-Top5 在训练阶段即表现出稳定优势.附录表 S5 结果显示,

SOBLE-Top5 在春、夏、秋、冬四季训练集上的 R^2 分别为 0.932 3、0.894 4、0.889 3 和 0.958 6,对应 $RMSE$ 分别为 0.021 9、0.030 3、0.023 2 和 0.014 2 m^3/m^3 , MAE 分别为 0.016 0、0.022 7、0.017 0 和 0.010 4 m^3/m^3 ,整体均优于对比单模型,表明其在不同季节样本分布下具有较好的拟合能力与训练稳定性。

3.3 降尺度 SSM 站点验证与时序一致性

3.3.1 深度不匹配灵敏度分析

为评估 SMAP 表层土壤水分代表深度(约 5 cm)与站点观测深度(10 cm)不一致带来的影响,本文基于 10 cm 站点观测数据开展深度不匹配敏感性分析。以 10 cm 观测值为基准($\Delta=0$),构建“5 cm 类似”参考序列 $SM5=SM10\pm\Delta$,其中 Δ 取 0.01 和 0.02 m^3/m^3 ,用于表示表层相对 10 cm 层偏湿或偏干的情景,并重新计算 $Bias$ 和 $RMSE$ 。附录图 S3 结果显示, $Bias$ 随 Δ 近似呈 1:1 线性变化,说明深度不匹配主要表现为系统性偏移;当 $|\Delta|=0.02 m^3/m^3$ 时, $Bias$ 约为 $\pm 0.02 m^3/m^3$ 。相比之下, $RMSE$ 对 Δ 的敏感性较弱,由基准情景下的 0.051 42 m^3/m^3 增至最大 0.055 21 m^3/m^3 。总体来看,深度不匹配主要影响系统偏差,对总体误差幅度影响相对有限,可为站点验证结果提供不确定性参考。

3.3.2 站点尺度散点验证结果

基于站点观测的验证结果表明,SOBLE-Top5 季节性降尺度模型能够较好地重建表层土壤水分变化,但其性能随季节变化而呈现阶段性差异。图 1 显示,冬季模型表现较为稳定;3 至 4 月估计值与观测值吻合较好;而 5 月由于快速升温引起地表能量条件突变,SSM 波动增强,相关性出现明显下降,反映出模型对春季快速水热变化的响应仍有提升空间。进入夏季后,模型精度有所恢复,相关系数 R 约为 0.656~0.756;7 月受强降水影响出现最大正偏差(约 0.023 m^3/m^3)。秋季反演效果最佳且相对稳定,其中 9 月达到较优表现($R=0.864$, $RMSE=0.028 m^3/m^3$)。总体而言,站点散点验证结果与季节性建模和集成模型对比结果相一致,说明该方法不仅在统计指标上具有优势,也在站点尺度保持了较好的观测一致性。

3.3.3 典型站点长时序对比结果

如图 2 所示,SOBLE-Top5 在建筑物、农作物、森林和草地 4 类典型站点均表现出较好的时序一致性。其中,建筑区效果最佳($R^2=0.80$, $R=0.89$),优于原始 SMAP SSM($R^2=0.71$, $R=0.84$);农作物、森林和草地区域也保持了较高相关性($R>0.73$),说明降尺度结果能够较好反映不同地类下 SSM 的季节变化。时序曲线进一步表明,SOBLE-Top5 不仅保留了原始 SMAP SSM 的总体变化趋势,而且与站点观测具有更好的同步性并合理响应降水事件。降雨事件后,各类站点 SSM 均出现不同程度上升,表明模型较好保持了土壤水分对降水脉冲的物理响应特征。相对而言,春季尤其 5 月受快速升温、植被返青和农田管理活动影响,模型对短时剧烈波动的刻画仍有一定不足,后续可通过引入物候信息或冻融指标进一步改进。

3.4 1 km 降尺度 SSM 时空分布特征

3.4.1 月尺度空间分布格局

图 3 显示,冬季 SSM 整体较稳定,区域平均值约为 0.228 m^3/m^3 ,豫南部分地区受局部雨雪影响略有升高。春季随气温回升和蒸发增强,北部地区 SSM 逐渐下降;5-6 月全省进入年度低值阶段,月均 SSM 分别降至 0.138 m^3/m^3 和 0.136 m^3/m^3 ,安阳、鹤壁、濮阳、焦作和新乡等地出现局部低值区,表明降尺度结果能够较好地刻画区域干湿分异。7-8 月受汛期降水影响,区域 SSM 明显回升,月均值分别增至 0.243 m^3/m^3 和 0.232 m^3/m^3 ,周口、商丘、濮阳、驻马店和南阳等地变化较为显著,说明降尺度结果能够反映降水驱动的湿化过程。秋季 SSM 呈“先稳后升”特征,9 月和 10 月均值分别为 0.166 m^3/m^3 和 0.167 m^3/m^3 ,11 月升至 0.194 m^3/m^3 。空间上,研究区 SSM 总体表现出南部高、北部低的分布特征,反映了降水、地形和下垫面差异对土壤水分空间格局的共同影响。

3.4.2 关键时段时空演变特征

为进一步揭示生长季关键阶段的细尺度变化,对 3-7 月进行旬尺度分析。定量统计进一步表明(附录图 S4),中度干旱阈值对应的低湿区($SSM<0.15 m^3/m^3$)面积由 3 月下旬的 7 120 km^2 增加至 5 月下旬的 95 885 km^2 并达到峰值;重度低湿区($SSM<0.10 m^3/m^3$)在 4 月中旬至 6 月上旬快速扩张,峰值出现在 6 月上旬(28 974 km^2)。6 月中旬以后,各等级低湿区开始收缩,至 7 月高 SSM 区在豫南及西部山区重新扩展,但豫中北部仍存在残留低值区。该过程与春末初夏蒸散增强、降水偏少以及入汛后降水增加的季节转换规律一致。




图1 季节性模型(SOBLE-Top5)降尺度反演的SSM及站点验证

Fig.1 Downscaled SSM retrieved by the seasonal model(SOBLE-Top5) and validation against in situ observations

4 驱动机制解释与讨论

4.1 季节性主导驱动因子识别

总体来看,SSM 驱动机制具有明显季节差异,表现为冷季土壤属性因子主导,暖季地形、植被、能量和降水因子共同作用(附录图 S5).

(1)土壤容重(BD)和黏粒含量(Clay)在冷季贡献较高.BD 对 SSM 呈明显阈值效应,低容重土壤通常对应正 SHAP 值,表明疏松土壤更有利于入渗和蓄水;当 BD 升高后,SHAP 值逐渐转负,说明土壤紧实化会抑制水分保持.Clay 在四季均具有较高贡献,较高黏粒含量通常对应更强的持水能力.

(2)地形因子在夏秋季作用增强.低海拔区域多对应正 SHAP 值,而高海拔区域 SHAP 值趋于降低,反映了地形-气候梯度对土壤水分空间分布的影响.坡度在春季和秋季多表现为负效应,说明在降水偏少或径流增强条件下,陡坡区更易出现水分亏缺.

(3)植被、能量和气象因子主要影响暖季 SSM 变化.NDVI 和 LAI 对 SSM 的影响呈非线性特征,低-中等植被覆盖有助于抑制蒸发,而高覆盖度下蒸腾消耗增强.LST 在春夏季表现为关键负驱动因子,温度升高会加剧蒸散并降低 SSM.夏季降水对 SSM 贡献显著且多为正效应,说明降水是暖季土壤水分恢复的重要驱动.Albedo-VIS 在夏秋季保持一定贡献,反映地表辐射条件对土壤水热过程的调节作用.




图2 日降水量、SOBLE-Top5 SSM、SMAP SSM和In-situ时间动态变化序列

Fig.2 Temporal variations of daily precipitation, SOBLE-Top5 SSM, SMAP SSM and in situ observations at representative sites

4.2 不确定性、局限性与方法适用性讨论

4.2.1 冻融/积雪及观测缺口对结果解释的影响

虽冬季模型误差较低、拟合度较高,但研究在考虑观测覆盖约束后识别到多次区域性雪事件,表明冬季SSM可能受到积雪堆积/融化过程影响,且SMAP的有效可观测性与误差结构可能与其他季节存在系统差异.因此,冬季较低误差更应理解为特定过程背景下的预测能力变化,而非无条件的性能提升.后续工作可将冻融指标、雪水当量或雪盖持续时间等变量纳入候选驱动因子,进一步提升冬季过程一致性与解释稳健性.

4.2.2 跨区域迁移与跨年泛化能力限制

研究时段主要覆盖2023年12月至2024年11月,空间上聚焦河南省.该设置有利于开展单区域、单年的季节机制分析,但对跨年气候异常(如持续性高温干旱、异常汛期)和跨区域地表条件差异的泛化能力仍缺乏系统验证.此外,站点时序验证结果显示,春季(尤其5月)在快速升温与植被迅速绿化背景下,模型对短时、大幅度SSM波动的响应能力仍有限.这说明模型对春季复杂水热耦合过程和植被生理动态的表征仍有提升空间,也从侧面反映了跨年、跨情景泛化能力的潜在约束.后续建议开展:(1)跨年份扩展实验(至少3至5a);(2)跨区域迁移验证(平原-丘陵-山地复合区);(3)区域适配与迁移学习/领域自适应对比,以系统评估方法的可迁移性.

4.2.3 性能-效率权衡与工程应用潜力

从工程实现角度看,集成学习方法(尤其Stacking)提升了精度与稳健性,但也带来训练与推理成本增

加.随着基础学习器数量增加,训练时间通常上升;性能在多数设置下有所改善,但部分策略-规模组合存在边际收益递减甚至性能下降的情况,提示集成规模并非越大越优.因此,在工程应用中应兼顾“精度-时效-资源”三维约束:面向业务化日尺度制图,可优先采用经验证的Top-*k* 组合(如 SOBLE-Top5)作为精度优先方案;若面向实时性更高的预警场景,可考虑模型压缩、轻量元学习器或动态集成策略.

5 结论

本文以河南省为研究区,融合 SMAP L4 SSM、遥感植被与能量因子、气象降水因子、土壤属性和地形因子,构建了多源驱动与季节性集成学习相结合的 1 km 日尺度表层土壤水分降尺度方法.主要结论如下:

- 1)分季节建模整体优于全年统一建模,能够更好地刻画不同季节下 SSM 与环境因子之间的非线性关系,尤其在春季和冬季表现出更明显的精度提升.
- 2)SOBLE-Top5 集成模型在四季测试集中均取得较好效果,春、夏、秋、冬 R^2 分别为 0.938 9、0.907 8、0.897 7和 0.963 2, $RMSE$ 分别为 0.020 8、0.029 1、0.022 2 和 0.013 3 m^3/m^3 ,表明 Top-*k* 优选与 Stacking 集成能够有效提升模型稳定性和泛化能力.
- 3)站点验证和 SHAP 分析表明,降尺度结果能够较好地反映不同地表覆盖类型下 SSM 的时序变化和降水响应特征.SSM 驱动机制具有明显季节差异,整体表现为冷季土壤属性主导、暖季多因子协同驱动.
- 总体来看,本文方法能够提升 SMAP SSM 的空间分辨率、预测精度和解释性,可为区域农业干旱监测和水资源管理提供高分辨率土壤水分数据支持.

附录见电子版(DOI:10.16366/j.cnki.1000-2367.2026.03.11.0001).

参 考 文 献

[1] 王晓燕,李净,邢立亭.基于 3 种机器学习方法的农业干旱监测比较[J].干旱区研究,2022,39(1):322-332.
Wang X Y,Li J,Xing L T.Comparative agricultural drought monitoring based on three machine learning methods[J].Arid Zone Research,2022,39(1):322-332.

[2] 王晓东,陈金华,陈曦,等.淮河流域农田旱涝逐日监测指标优化及适用性分析[J].农业工程学报,2021,37(23):117-126.
Wang X D,Chen J H,Chen X,et al.Optimization and applicability analysis of daily farmland drought and flood monitoring index in Huaihe River Basin[J].Transactions of the Chinese Society of Agricultural Engineering,2021,37(23):117-126.

[3] Entekhabi D,Njoku E G,O'Neill P,et al.The soil moisture active passive(SMAP) mission[J].Proceedings of the IEEE,2010,98(5):704-716.

[4] Reichle R H,De Lannoy G J M,Liu Q,et al.Global assessment of the SMAP level-4 surface and root-zone soil moisture product using assimilation diagnostics[J].Journal of Hydrometeorology,2017,18(12):3217-3237.

[5] Ur Rahman K,Shang S H,Balkhair K,et al.Catchment-scale drought propagation assessment in the Indus Basin of Pakistan using a combined approach of principal components and wavelet analyses[J].Journal of Hydrometeorology,2023,24(4):601-624.

[6] Colliander A,Fisher J B,Halverson G,et al.Spatial downscaling of SMAP soil moisture using MODIS land surface temperature and NDVI during SMAPVEX15[J].IEEE Geoscience and Remote Sensing Letters,2017,14(11):2107-2111.

[7] Colliander A,Reichle R H,Crow W T,et al.Validation of soil moisture data products from the NASA SMAP mission[J].IEEE Journal of




图3 SOBLE-Top5降尺度反演1 km月尺度SSM空间分布结果
Fig.3 Spatial distribution of monthly 1 km SSM downscaled using SOBLE-Top5

Selected Topics in Applied Earth Observations and Remote Sensing,2022,15:364-392.

[8] Teixeira A C,Bakon M,Lopes D,et al.A systematic review on soil moisture estimation using remote sensing data for agricultural applications[J].Science of Remote Sensing,2025,12:100328.

[9] Ben Abbes A,Jarray N,Farah I R.Advances in remote sensing based soil moisture retrieval:applications,techniques,scales and challenges for combining machine learning and physical models[J].Artificial Intelligence Review,2024,57(9):224.

[10] Senanayake I P,Pathira Arachchilage K R L,Yeo I Y,et al.Spatial downscaling of satellite-based soil moisture products using machine learning techniques:a review[J].Remote Sensing,2024,16(12):2067.

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

[12] Massoud E C, Lee H,Gibson P B,et al.Bayesian model averaging of climate model projections constrained by precipitation observations over the contiguous United States[J].Journal of Hydrometeorology,2020,21(10):2401-2418.

[13] 马柱国,魏和林,符淙斌.土壤湿度与气候变化关系的研究进展与展望[J].地球科学进展,1999,14(3):299-305.
Ma Z G,Wei H L,Fu C B.Progress in the research on the relationship between soil moisture and climate change[J].Advances in Earth Science,1999,14(3):299-305.

[14] 鲍琳.多源遥感数据协同解译地表土壤湿度变化研究[D].西安:长安大学,2023.
Bao L.Collaborative interpretation of surface soil moisture changes with multi-source remote sensing data[D].Xian:Changan University,2023.

[15] Meng X J,Zeng J Y,Yang Y B,et al.High-resolution soil moisture mapping through passive microwave remote sensing downscaling[J].The Innovation Geoscience,2024,2(4):100105.

[16] Singh A,Niranjannaik M,Gaurav K.Downscaling SMAP soil moisture using a hybrid machine-learning algorithm[J].Applied Soft Computing,2026,193:114766.

[17] Wang J,Xue H Z,Dong G T,et al.Downscaling of remote sensing soil moisture products that integrate microwave and optical data[J].Applied Sciences,2024,14(24):11875.

[18] Yang N,Xiang F,Zhang H J.The characterization of the vertical distribution of surface soil moisture using ISMN multilayer in situ data and their comparison with SMOS and SMAP soil moisture products[J].Remote Sensing,2023,15(16):3930.

[19] Mosca E,Szigeti F,Tragianni S,et al.SHAP-based explanation methods;a review for NLP interpretability[C]//Proceedings of the 29th International Conference on Computational Linguistics,Gyeongju,Republic of Korea Association for Computational Linguistics,2022:4593-4603.

Downscaling SMAP surface soil moisture using multi-source drivers and seasonal ensemble learning


Zhang Chunfang¹, Zhu Shengmin², Pan Deng³, Meng Wenmin¹, Yu Haiyang²

(1. Henan Jiaozuo Hydrology and Water Resources Forecasting Sub-center, Jiaozuo 475008, China; 2. Key Laboratory of Mine Spatio-temporal Information and Ecological Restoration, Ministry of Natural Resources, Henan Polytechnic University, Jiaozuo 454000, China; 3. Institute of Natural Resources Monitoring and Comprehensive Land Improvement of Henan Province, Zhengzhou 450199, China)

Abstract: To address the problem that soil moisture active passive(SMAP) soil moisture products have coarse spatial resolution and are insufficient for regional fine-scale applications, this study proposes a 1 km daily-scale surface soil moisture (SSM) downscaling method that integrates multi-source driving factors with seasonal ensemble learning, sampling Henan Province as the study area. SMAP L4 SSM was used as the target variable, and remote sensing vegetation and energy factors, meteorological precipitation factors, soil properties, and topographic factors were integrated. A "9 km training-1 km inference" strategy was adopted, and a seasonal ensemble model named SOBLE-Top5 was constructed based on Top-*k* selection and Stacking. The results show that seasonal modeling generally outperformed annual unified modeling. The *R*² values of SOBLE-Top5 on the spring, summer, autumn, and winter test sets were 0.938 9, 0.907 8, 0.897 7 and 0.963 2, respectively, while the root mean square error(RMSE) values were 0.020 8, 0.029 1, 0.022 2, and 0.013 3 m³/m³, respectively. Site-based validation indicated that the downscaled results effectively captured the temporal variations of SSM under different land-cover types. SHAP analysis revealed pronounced seasonal differences in the driving mechanisms of SSM, generally characterized by "soil-property dominance in cold seasons and multi-factor synergistic control in warm seasons." This study can provide high-resolution soil moisture data support for regional agricultural drought monitoring and water resource management.

Keywords: SMAP; surface soil moisture; downscaling; seasonal modeling; ensemble learning


附 录



注:该图根据审图号GS(2019)1882号的标准地图制作,底图无修改.

图S1 研究区位置与站点分布图

Fig.S1 Location of the study area and distribution of monitoring sites



图S2 总体降尺度技术框架

Fig.S2 Overall technical framework of the downscaling approach

表 S1 本研究公式

Tab. S1 The formula of this study

序号	公式	说明
(1)	$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}}$	ρ_{nir} 、 ρ_{red} 、 ρ_{blue} 分别表示近红外、红光和蓝光波段的反射率,
(2)	$EVI = G \times \frac{\rho_{nir} - \rho_{red}}{L + \rho_{nir} + C_1 \times \rho_{red} - C_2 \times \rho_{blue}}$	ρ_{swir1} 、 ρ_{swir2} 、 ρ_{swir3} 分别表示短波红外 1、2、3 波段的反射率, $G = 2.5$ 是增益系数,冠层背景调整系数 $L = 1$, $C_1 = 6.0$ 和 $C_2 = 7.5$ 是气溶胶阻力权重.
(3)	$NDWI = \frac{\rho_{nir} - \rho_{swir1}}{\rho_{nir} + \rho_{swir1}}$	
(4)	$NMDI = \frac{\rho_{swir2} - (\rho_{nir} + \rho_{swir3})}{\rho_{swir2} + (\rho_{nir} + \rho_{swir3})}$	
(5)	$slope(radian) = \tan(slope(degree))$	$slope$ 由 SRTM DEM 计算得到;流积累积 ($flow accumulation$) 采用 Hydro SHEDS 15 s 流积累积数据进行提取.
(6)	$TWI = \ln(\frac{flow accumulation}{\tan(slope)})$	
(7)	$R = \frac{\sum_{i=1}^N (x_i^P - x_{Mean}^P)(x_i^M - x_{Mean}^M)}{\sqrt{\sum_{i=1}^N (x_i^P - x_{Mean}^P)^2} \sqrt{\sum_{i=1}^N (x_i^M - x_{Mean}^M)^2}}$	N 为实测或估计的 SSM 样本点个数.此外, x_i^P 和 x_i^M 分别表示第 i 个预测 SSM 和第 i 个实测 SSM. x_{Mean}^P 和 x_{Mean}^M 分别表示预测 SSM 和实测 SSM 的平均值. R 介于 $[-1, 1]$ 区间, 当 R 介于 $(0, 1]$ 区间时, 表明 x_i^P 和 x_i^M 之间呈正相关; 当 R 介于 $[-1, 0)$ 区间时, 表明 x_i^P 和 x_i^M 之间呈负相关; 当 R 为 0 时, 二者之间不存在相关性. 需要强调的是, 在降尺度研究中单一指标可能产生偏判. 因此, 本文采用多指标联合评价, 并以测试集结果作为方法优选依据.
(8)	$R^2 = 1 - \frac{\sum_{i=1}^N (x_i^M - x_i^P)^2}{\sum_{i=1}^N (x_i^M - x_{Mean}^M)^2}$	
(9)	$Bias = \frac{1}{n} \sum_{i=1}^N (x_i^M - x_{Mean}^M)$	
(10)	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i^P - x_i^M)^2}$	
(11)	$MAE = \frac{1}{N} \sum_{i=1}^N x_i^P - x_i^M $	

表 S2 各季节样本数量统计表(训练/测试)

Tab. S2 Statistics of sample numbers for each season(training/testing)

季节划分	时间/d	训练集样本数	测试集样本数
冬季(12-次年 2 月)	91	158 613	67 977
春季(3-5 月)	92	160 356	68 724
夏季(6-8 月)	92	160 356	68 724
秋季(9-11 月)	91	158 613	67 977
全年	366	637 938	273 402

表 S3 分季节与全季节基模型性能对比

Tab. S3 Performance comparison of base models between seasonal and all-season modeling

模型	冬季		春季		夏季		秋季		全季节	
	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2
ET	0.015 7	0.949 3	0.028 3	0.886 9	0.034 1	0.872 7	0.025 6	0.864 7	0.029 9	0.869 7
RF	0.015 9	0.947 9	0.027 8	0.890 9	0.037 0	0.849 7	0.028 0	0.839 0	0.031 7	0.833 4
KNN	0.024 0	0.881 0	0.030 4	0.868 9	0.046 9	0.759 2	0.031 9	0.790 4	0.041 8	0.744 3
XgBoost	0.025 4	0.866 4	0.032 1	0.854 0	0.041 6	0.810 2	0.032 1	0.787 5	0.042 5	0.736 7
CatBoost	0.025 4	0.866 4	0.031 8	0.856 8	0.042 1	0.806 0	0.032 7	0.779 6	0.041 1	0.753 5
Lightgbm	0.035 7	0.737 1	0.041 1	0.761 0	0.050 5	0.721 0	0.040 4	0.663 9	0.051 1	0.612 9

表 S4 不同集成策略的降尺度模型性能对比


Tab. S4 Performance comparison of downscaling models under different ensemble strategies

集成方式	集成数量	季节							
		冬季		春季		夏季		冬季	
		RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²
Blender	Top 2	0.020 8	0.912 7	0.026 9	0.897 3	0.037 6	0.844 9	0.026 2	0.020 8
	Top 3	0.020 8	0.917 3	0.027 3	0.894 2	0.036 5	0.853 9	0.025 6	0.020 8
	Top 4	0.021 9	0.907 8	0.029 7	0.875 3	0.036 9	0.851 0	0.025 9	0.021 9
	Top 5	0.023 2	0.896 6	0.028 5	0.885 2	0.036 6	0.853 0	0.026 6	0.023 2
Stacking(Linear regression)	Top 2	0.019 0	0.930 9	0.025 9	0.905 1	0.032 9	0.881 1	0.025 2	0.019 0
	Top 3	0.018 5	0.934 5	0.025 7	0.906 4	0.032 7	0.883 0	0.027 0	0.018 5
	Top 4	0.018 5	0.934 5	0.025 4	0.908 7	0.032 7	0.883 1	0.026 0	0.018 5
	Top 5	0.018 5	0.934 5	0.024 7	0.870 0	0.032 4	0.884 8	0.026 0	0.018 5
Stacking(Optimal basic learner)	Top 2	0.014 3	0.957 7	0.024 6	0.914 1	0.031 7	0.890 0	0.024 5	0.014 3
	Top 3	0.014 2	0.958 5	0.022 1	0.930 7	0.031 1	0.895 0	0.023 4	0.014 2
	Top 4	0.014 2	0.958 5	0.021 9	0.932 3	0.030 8	0.896 3	0.023 2	0.014 2
	Top 5	0.014 1	0.958 6	0.021 9	0.932 3	0.030 3	0.899 4	0.023 2	0.014 1


表 S5 各季节不同模型的性能对比

Tab. S5 Performance comparison of different models across seasons



模型	变量	冬季		春季		夏季		秋季	
		训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
DNN	R ²	0.862 5	0.855 6	0.855 8	0.838 6	0.750 8	0.729 0	0.728 9	0.746 9
	RMSE	0.025 8	0.026 4	0.031 9	0.033 7	0.047 7	0.049 8	0.036 2	0.034 9
	MAE	0.019 3	0.020 0	0.024 6	0.026 0	0.037 2	0.038 8	0.025 7	0.027 0
GBM	R ²	0.928 4	0.913 2	0.914 4	0.887 5	0.871 5	0.838 2	0.862 5	0.828 3
	RMSE	0.018 6	0.020 5	0.024 6	0.028 2	0.034 3	0.038 5	0.025 8	0.028 7
	MAE	0.014 2	0.015 7	0.019 0	0.021 8	0.026 3	0.029 8	0.020 0	0.022 4
DRF	R ²	0.938 6	0.912 3	0.906 0	0.845 3	0.882 9	0.815 0	0.870 9	0.802 9
	RMSE	0.017 2	0.020 6	0.025 8	0.033 0	0.032 7	0.041 2	0.025 1	0.030 8
	MAE	0.013 1	0.015 6	0.019 8	0.025 4	0.025 4	0.032 0	0.019 4	0.023 8
SOBLE-TOP5	R ²	0.958 6	0.963 2	0.932 3	0.938 9	0.894 4	0.907 8	0.889 3	0.897 7
	RMSE	0.014 2	0.013 3	0.021 9	0.020 8	0.030 3	0.029 1	0.023 2	0.022 2
	MAE	0.010 4	0.009 7	0.016 0	0.015 1	0.022 7	0.021 7	0.017 0	0.016 7





图S3 验证指标对深度不匹配(5 cm 与 10 cm)灵敏度的分析
Fig.S3 Sensitivity of validation metrics to depth mismatch(5 cm vs 10 cm)



图S4 不同SSM阈值下的面积变化(旬尺度)
Fig.S4 Variations in area under different SSM thresholds(10-day scale)



冬季



春季

