

辐射传输耦合集成学习的堆叠模型在多源遥感数据融合反演土壤含水率的潜力

李睿骐^{1,2} 李旺业^{1,2} 胡国强² 葛茂生^{1,2} 樊帅龙^{1,2} 刘路^{1,2} 钱龙^{1,2}
白旭乾^{1,2} 张智韬^{1,2} 陈俊英^{1,2} 边江^{1,2} 惠鑫^{1,2}

(1. 旱区农业新疆研究院, 乌鲁木齐 830091; 2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100)

摘要: 土壤含水率(SMC)是农业水分管理与干旱监测的关键参数,准确估算 SMC 对于推动农业可持续发展至关重要。目前,由于经验模型过于依赖统计关系,导致普适性与可移植性较差;而物理模型虽具明确机理,但在复杂环境下常需做简化,因此单一模型估算 SMC 的精度仍面临挑战,有必要探索融合经验与物理机制的混合建模策略,以提升 SMC 估算的稳定性与泛化能力。针对这一问题,以新疆生产建设兵团农八师为研究区域,以 Sentinel-1/2 卫星为数据源,以地面实测高光谱数据为辅助,耦合辐射传输模型与集成学习,本文提出了一种基于土壤辐射传输模型(BSM)的 Sentinel-1/2 融合反演土壤含水率模型。基于实测土壤高光谱数据率定 BSM 模型参数范围,结合光谱响应函数和 BSM 模型模拟 Sentinel-2 反射率,作用于模型训练,并对实测数据进行验证。将验证结果作为堆叠模型的第2层输入变量,结合 Sentinel-1 雷达后向散射系数及其纹理特征,使用 XGboost、GRBT、AdaBoost 估算 SMC。结果表明:在 BSM 模型参数范围的率定中,模型参数 lat 和 lon 表现出良好的线性关系,相较于未率定参数的土壤含水率第1层反演模型($R^2 = -1.143$)精度提升至 $R^2 = 0.368$;基于土壤辐射传输模型与 Sentinel-1 卫星的融合算法反演 SMC 精度优于机器学习模型,验证集决定系数 R^2 达 0.816;融合 Sentinel-1 雷达后向散射系数及其纹理特征和 Sentinel-2 多光谱构建的混合模型中,AdaBoost 展现出最佳的反演精度,验证集 R^2 达到 0.816,验证了经验模型与基于物理的模型在反演 SMC 过程中的互补潜力。本研究强调了混合方法兼具物理模型的泛化能力与经验模型的灵活性,为研究区域土壤含水率实时监测及土地资源可持续管理提供了新的技术手段。

关键词: 土壤含水率; BSM 辐射传输模型; Sentinel-1/2; 堆叠学习; 高光谱

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2026)20-0082-12

OSID:



Potential of Stacked Model Integrating Radiation Transfer Coupling and Ensemble Learning for Soil Moisture Content Retrieval from Multi-source Remote Sensing Data

Li Ruiqi^{1,2} Li Wangye^{1,2} Hu Guoqiang² Ge Maosheng^{1,2} Fan Shuailong^{1,2} Liu Lu^{1,2}
Qian Long^{1,2} Bai Xuqian^{1,2} Zhang Zhitao^{1,2} Chen Junying^{1,2} Bian Jiang^{1,2} Hui Xin^{1,2}

(1. Xinjiang Research Institute of Agriculture in Arid Areas, Urumqi 830091, China

2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Soil moisture content (SMC) is a key parameter in agricultural water management and drought monitoring, and accurate estimation of SMC is crucial for promoting sustainable agricultural development. Currently, due to the excessive reliance of empirical models on statistical relationships, their universality and portability are poor. Although physical models have clear mechanisms, they often need to be simplified in complex environments. Therefore, the accuracy of single model estimation of SMC is still facing challenges. It is necessary to explore a hybrid modeling strategy integrating experience and physical mechanisms to improve the stability and generalization of SMC estimation. In response to this issue, taking the Agricultural Eighth Division of Xinjiang Production and Construction Corps as the research area, using Sentinel-1/2 satellite as the data source, and ground measured hyperspectral data as the auxiliary, the radiative transfer model and ensemble learning was coupled, and a Sentinel-1/2

收稿日期: 2026-07-03 修回日期: 2026-07-20

基金项目: 旱区农业新疆研究院农业科技创新专项(XJHQNY-2025-3)和国家重点研发计划项目(2022YFD1900404-01)

作者简介: 李睿骐(2002—),男,博士生,主要从事农业遥感与水文水资源研究,E-mail: liruiqi999@126.com

通信作者: 葛茂生(1990—),男,教授,博士生导师,主要从事农业遥感与水文水资源研究,E-mail: zhitaozhang@126.com

fusion inversion soil moisture content model was proposed based on soil radiative transfer model (BSM). This method firstly calibrated the parameter range of the BSM model based on measured soil hyperspectral data, and then combined the spectral response function and BSM model to simulate Sentinel - 2 reflectance, applied it to model training, and verified the measured data. Finally, the validation results would be used as input variables for the second layer of the stacked model, combined with the Sentinel - 1 radar backscatter coefficient and its texture features, to estimate SMC using XGboost, GRBT, and AdaBoost. The results showed that in the calibration of the parameter range of the BSM model, the model parameters lat and lon exhibited a good linear relationship ($R^2 = 0.545$), and the accuracy was improved as $R^2 = 0.368$ compared with the first layer inversion model of soil moisture content without calibration parameters ($R^2 = -1.143$). The fusion algorithm based on soil radiative transfer model and Sentinel - 1 satellite had better accuracy in retrieving SMC than the machine learning model, with a validation set determination coefficient R^2 of 0.816. In the hybrid model constructed by integrating the backscatter coefficient and texture features of Sentinel - 1 radar with Sentinel - 2 multispectral, AdaBoost showed the best inversion accuracy, with a validation set R^2 of 0.816, verifying the complementary potential of empirical and physics based models in the inversion of SMC. The research result emphasized that hybrid methods combined the generalization ability of physical models with the flexibility of empirical models, providing technological means for real-time monitoring of soil moisture and sustainable management of land resources in the research area.

Key words: soil moisture content; BSM radiative transfer model; Sentinel - 1/2; stacked learning; hyperspectral

0 引言

土壤含水率 (Soil moisture content, SMC) 是农业生产的重要环境因素,其动态变化对作物生长和农业水资源管理具有深远影响。土壤含水率时空分布特征与作物的生理活动密切相关,同时,SMC 监测数据为农田灌溉决策提供了科学依据。准确预测 SMC 不仅支持干旱预警系统的建立,也为作物产量模型提供了关键输入参数^[1]。因此,研究土壤含水率动态监测与预测,对于优化农业水资源配置和保障粮食安全具有重要的理论和实践意义。

传统土壤含水率地面测量方法 (如烘干法和时域反射仪) 虽精度较高,但由于观测点稀疏和人力成本高,难以满足区域尺度动态监测需求^[2]。遥感技术凭借广泛的覆盖范围和较短的监测周期,已成为土壤含水率估算的重要工具。卫星遥感技术能够快速、准确地进行大范围实时监测,克服了传统方法的高成本和低效率问题^[3]。近年来,利用多源遥感数据进行土壤含水率的定量反演研究逐渐增多。例如,Mu 等^[4]结合 GF - 2/3/5 数据开发了一种非线性 Erf - BP 神经网络方法反演土壤含水率。Meng 等^[5]则通过改进 Dubois 模型,基于 Radarsat - 2 和 Landsat - 8 数据反演了玉米各生育阶段的土壤含水率。

在这些遥感反演土壤含水率方法中,大致分为经验模型和基于物理模型的方法 2 大类。经验模型基于统计关系,通过建立遥感观测数据与地面实测土壤含水率的回归模型实现反演,优势在于计算简

单、对数据要求低,且在特定区域精度较高^[6]。例如,Guo 等^[7]通过融合雷达与多光谱数据,对内蒙古解放闸灌区的土壤含水率实现反演。张智韬等^[8]通过构建水云模型,采用机器学习对雷达与高光谱数据进行融合,实现了土壤含水率监测。由于经验模型本质上依赖统计关系,适用范围通常受限于特定区域和样本条件,同时采用的黑箱机器学习并没有对变量进行合理的机理解释,难以实现跨区域、跨时段的稳定应用,一旦土壤类型或性质发生变化,利用卫星光谱指数进行统计回归的经验模型精度往往迅速下降,因此这类方法的推广性和适用性较差。相比之下,基于物理模型通过土壤高光谱数据,显式描述了电磁波与土壤介质之间的相互作用,能够揭示高光谱数据与土壤含水率之间的机理联系,具有更强的可解释性与泛化能力^[9]。目前存在几种土壤辐射传输模型,例如亮度-形状-湿度模型 (Bright - shape - moisture model, BSM)^[10]、MARMIT 模型^[11]等,这些模型最初常作为下垫面反射率的模拟层,与冠层及大气辐射传输模型耦合,用于校正植被生理参数反演过程土壤背景的干扰,并在多种生态环境中取得了良好效果。例如 Yang 等^[10]开发了一种辐射传输模型,耦合了土壤-植被-大气系统的辐射传输子模型,实现了利用合成数据集和卫星数据集中以合理的精度估计植被属性以及大气属性和冠层反射率。Jiang 等^[12]开发了通用光谱矢量模型,采用 3 个干光谱向量和 1 个湿润光谱向量,准确模拟了全球范围内土壤高光谱反射率。然而,实现辐射传输模型复杂,反演需要大量的资源与计算,可能导致

SMC 建模存在相当大的不确定性。同时,纯光学土壤辐射传输模型在描述土壤含水率时,主要依赖反射率在水分吸收波段的响应,易受土壤性质、粗糙度及矿物类型的影响,反演结果存在一定的不确定性。因此在土壤含水率遥感反演研究中,将基于土壤辐射传输理论的物理模型与数据驱动的经验模型相融合构建混合模型,已成为在不同土壤类型的条件下提高 SMC 反演精度的重要研究趋势。

在 BSM 土壤辐射传输模型中,Jiang 等^[12]研究结果表明,可以使用少量“基光谱”拟合任何给定的干燥土壤反射光谱。同时 Yang 等^[10]指出,关于水分对干燥土壤反射率光谱的影响可以使用水膜涂层方法进行模拟,将湿润土壤等效为覆盖薄水层的干燥土壤体系,用于描述水分对土壤光谱反射率的调制作用。然而,该方法在计算过程往往忽略了土壤的理化性质对土壤含水率反演的影响,导致在不同土壤类型、不同大田环境下表现出精度衰减。针对这一光学机理的固有局限,Sentinel-1 卫星所提供的合成孔径雷达数据,尤其是雷达后向散射系数及其纹理特征,能够在一定程度上与土壤辐射传输模型在水分描述方面相互补充。雷达后向散射信号对土壤介电常数和表面粗糙度相当敏感,其中介电常数的变化直接受土壤含水率控制,而表面粗糙度则影响散射机制与极化特征^[13]。例如周美玲等^[14]基于 Landsat8、Sentinel-2 和 Sentinel-1 联合反演表层土壤含水率,证明了经水云模型去除植被影响后,双极化方式反演土壤含水率精度较高。Yang 等^[15]探讨了偏振模态及表面粗糙度的先验知识对 SMC 反演的影响,展示出雷达系统的参数(介电常数、粗糙度等)与土壤含水率的高相关性。因此,通过 Sentinel-1 卫星的雷达数据补充土壤辐射传输模型中对土壤含水率描述的不足,构建物理方法与经验方法相结合的混合模型,能够为土壤含水率反演模型提供更强的精度提升,减少因土壤辐射传输模型假设简化带来的系统误差,并提升模型在多区域、多尺度条件下适用性与鲁棒性。

在反演土壤含水率的经验模型中,机器学习已从单纯的统计建模发展为多源数据协同分析的强大工具。传统机器学习方法(如支持向量机、随机森林)通过挖掘遥感数据与土壤含水率的非线性关系,显著提升了经验模型精度,但其依赖大量训练数据且难以解释模型物理机制^[16]。基于堆叠集成学习作为一种有效的集成学习方法,能够实现物理模型与集成学习进一步融合。Du 等^[17]分别使用机器学习算法、梯度提升回归树(Gradient boosting regressiontrees, GBRT)和极端梯度提升(eXtreme

gradient boosting, XGBoost)集成学习算法构建土壤水盐预测模型,结果表明 XGBoost 模型可以更好地反映作物生长期农田土壤水盐动态过程。Taghizadeh-Mehrjardi 等^[18]提出通过元学习模型堆叠集成机器学习模型的方法,证明集成学习模型对土壤有机碳(Soil organic carbon, SOC)含量的预测性得到了显著提升。堆叠集成学习在土壤性质预测中展现出更好的预测性能与稳定性,具有广泛的应用前景。

为了克服土壤辐射传输模型假设简化对土壤含水率反演的干扰,提升经验模型的物理约束,本研究采用混合建模策略,融合基于物理机制的 BSM 模型优势和集成学习模型方法的灵活性、高效性,构建高精度土壤含水率反演方法。构建基于 BSM 模型为基础的集成学习反演模型,利用卫星遥感数据检索农田 SMC,并根据实地数据验证估算值;利用地物波谱仪测量的土壤高光谱数据,率定 BSM 参数范围,探究土壤理化性质对 BSM 模型参数的影响;分析 3 种集成学习模型预测性能,探究所提混合模型在土壤含水率预测中的潜力。以期为研究区土壤含水率实时动态监测和农业可持续发展提供参考依据和技术支持。

1 材料和方法

1.1 研究区概况

如图 1 所示,研究区位于新疆生产建设兵团第八师,坐标为 44°20′~44°50′N,85°50′~86°24′E,处于天山北麓中段与准噶尔盆地南缘的交汇带。区域总面积 $1.4 \times 10^5 \text{ hm}^2$,涵盖石河子市、沙湾市和玛纳斯县 3 个行政区,农田以棉花种植为主,采用滴灌系统进行灌溉。地形呈明显的阶梯状分布:东南部为天山山区,向西北过渡为山前丘陵、倾斜平原及洪水冲积平原,海拔 311~453 m,平均坡度 12.3%。气候属典型的温带大陆性气候,特征为冬季寒冷、夏季炎热、昼夜温差显著,年均气温 7.5℃,年降雨量 180~270 mm,年蒸发量 1 000~1 500 mm^[19]。

1.2 数据采集及预处理

1.2.1 土壤含水率获取

在 2023 年、2024 年和 2025 年 4—5 月对棉花苗期进行了现场采样,均匀布设 86 个采样点(图 1)。在每个采样日期,按照五点采样法^[20]在土壤深度 0~10 cm 采集地表土样,并采用环刀法测量土壤容重,计算得到土壤体积含水率。

1.2.2 卫星数据及纹理特征获取

Sentinel-1 卫星系统由 A 和 B 2 颗卫星组成,具有交叉极化(VH)和垂直极化(VV)2 种极化模式。




图1 研究区域及采样点分布

Fig. 1 Distribution of research area and sampling points

卫星轨道高度约为 693 km,重访周期为 12 d。2 颗卫星配备了中心频率为 5.405 GHz 的 C 波段合成孔径雷达,并支持 4 种成像模式(SM、IW、EWS 和 WV),能够提供全天候的陆地和海洋雷达图像。本研究选择 Sentinel-1 的 IW 成像模式地距探测 GRD 产品。

Sentinel-2 卫星系统配备了多光谱成像仪(MSI),具有 13 个不同的光谱带,涵盖从可见光和近红外到短波红外范围。包括 2 颗高分辨率多光谱卫星,分别为 Sentinel-2A 和 Sentinel-2B,轨道高度约为 786 km,重访周期为 5 d,在研究区域的重访周期为 2~3 d^[21]。本研究选择 11 个波段(B1~B8、B8A、B11 和 B12)进行土壤含水率估算,这些波段涵盖了从可见光到短波红外光谱区域。

目前,基于灰度共生矩阵(Gray-level cooccurrence matrix, GLCM)提取图像纹理特征是最流行与常用的方法。通过 GLCM 提取 Sentinel-1 卫星图像中 VV、VH 极化波段的 8 个纹理特征,分别为对比度(Contrast, CON)、非相似性(Dissimilarity, DIS)、同质性(Homogeneity, HOM)、角二阶矩(Angular second moment, ASM)、熵(Entropy, ENT)、均值(Mean, MEAN)、方差(Variance, VAR)、相关性(Correlation, COR)^[22]。

Sentinel-1 和 Sentinel-2 的数据于 2024 年和 2025 年 5 月在研究区域收集,并且获取时间与野外土壤样本采集时间相近,通过 Google Earth Engine(GEE)进行数据下载。Sentinel-1 数据预处理主要在 SNAP 7.0 和 ENVI 5.3 中进行,包括:轨道校正、去除热噪声和边界噪声、辐射地形校准、应用精细李

滤波器进行散斑滤波、进行距离多普勒地形校正和提取雷达后向散射系数和纹理特征。Sentinel-2 L2A 级别的数据已经进行了大气校正,因此 Sentinel-2 图像预处理包括:将图像重采样到 20 m 空间分辨率,并将图像导出为“tif”格式;提取反射率^[8]。

1.2.3 地面实测高光谱数据获取

光谱采集采用美国 ASD 公司生产的 FieldSpec-3 型高光谱仪,测定时间选取当地时间 10:00—15:00,选择天气晴朗无风、视野良好的天气状况测定,以尽量减少太阳角度和树冠阴影的变化。高光谱仪采集范围为 350~2 500 nm,光谱采样间隔为 1 nm。测量时高光谱仪探头始终垂直于测量对象,获取土壤的高光谱数据。光谱测定前,采用反射率为 1 的漫反射参照板对仪器进行校正。为了使数据准确且具有代表性,每个样点以五点梅花状采样方式对土壤样点周边对象进行测量,取平均值作为监测点最终光谱值。异常光谱曲线去除和光谱均值输出均在 ViewSpecPro 软件中进行^[23]。

1.3 技术路线

图 2 为技术路线,通过耦合土壤辐射传输模型 BSM 与集成学习实现土壤含水率估算。具体步骤如下:①基于地面实测土壤高光谱数据,通过非线性最小二乘拟合率定 BSM 模型 lat 和 lon 参数范围,并模拟 10 000 条土壤高光谱数据与土壤含水率数据。②通过光谱响应函数将土壤高光谱数据转化为多光谱数据,并作为输入变量对土壤含水率第 1 层反演模型进行预训练,结合 Sentinel-2 多光谱数据对土壤含水率进行预测。③将第 1 层预测结果与




图2 技术路线

Fig. 2 Algorithm flowchart

Sentinel-1 雷达后向散射系数及其纹理特征作为模型第2层输入变量,通过集成学习构建土壤含水率反演模型并进行模型评估。

1.4 BSM 土壤辐射传输模型

BSM 模型能够模拟干燥和湿润土壤的各向同性反射率。亮度和光谱形状源自全球土壤矢量(GSV)模型,从全球土壤光谱库中得出的3个“基光谱”,可以拟合任何给定的干土反射光谱^[24]。GSV 土壤光谱向量集可用于仅使用3个系数的近似干土光谱,计算式为

$$R_{sdry} = \begin{bmatrix} G_1 & G_2 & G_3 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix} \tag{1}$$

式中 R_{sdry} ——干土光谱反射率

a_1, a_2, a_3 ——拟合系数

G_1, G_2, G_3 ——全局光谱数据

在 GSV 模型的基础上,Yang 等^[10]提出的 BSM 模型假设土壤亮度仅影响土壤反射率的“强度”,而土壤反射率的“形状”由其他因素决定,如粗糙度、有机质含量和矿物成分,因此可以通过强度-形状变换将土壤亮度效应与光谱形状效应分开,计算式为

$$a = \begin{bmatrix} B \sin(lat) \\ B \cos(lat) \sin(lon) \\ B \cos(lat) \sin(lon) \end{bmatrix} \tag{2}$$

式中 a ——拟合系数向量

B ——土壤亮度,决定土壤反射率

lat, lon ——土壤形状参数,℃

这种强度-形状变换类似于将笛卡尔坐标转换为球面坐标。因此, lat 和 lon 类似于地球上的纬度和经度。

GSV 模型仅用于模拟干土反射率,而不模拟湿土反射率。土壤含水率对土壤反射率的影响通过使用水膜涂层方法的物理模型描述。水膜涂层方法^[24]将湿土视为覆盖有薄水层的干燥土层系统,在这种方法中,干土加水膜(即湿土)组合的反射率包括覆盖土壤颗粒的水膜和背景中水层底部与背景之间的多重反射,反射率计算式为

$$R_{swet}(k) = \rho_{12} + \frac{(1 - \rho_{12}) \exp(-2\kappa_w k \Delta) R_{bac}(1 - \rho_{21})}{1 - \rho_{21} \exp(-2\kappa_w k \Delta) R_{bac}} \tag{3}$$

式中 $R_{swet}(k)$ ——湿土反射率

ρ_{12}, ρ_{21} ——从一种介质到另一种介质的菲涅耳反射率

R_{bac} ——背景反射率

$\exp(-2\kappa_w k \Delta)$ ——水层双向透射率,随光学厚度而变化

κ_w ——吸水系数

Δ ——基本水膜光学厚度

k ——基本水膜数量

BSM 假设水膜厚度在空间上不规则(即单水膜、双水膜等), k 遵循泊松分布。对于不同厚度的水膜,仅改变了吸水引起的透射损耗,从而影响了水层的双向透射率(即 $\exp(-2\kappa_w k \Delta)$),因为表面反射率效应不受薄膜厚度的影响。因此,干土面积分数为 $P(k=0)$ 。综上所述,土壤反射率为

$$R_{soil} = R_{sdry} P(k=0) + \sum_{k=1}^{\infty} R_{swet}(k) P(k) \tag{4}$$

其中

$$P(k) = \frac{e^{-\mu} \mu^k}{k!} \tag{5}$$

$$\mu = \frac{SM_p - 5}{SM_c}$$

式中 μ ——水膜厚度期望值,并作为土壤含水率的函数给出
 SM_p ——土壤水分体积百分比
 SM_c ——土壤保水能力,取 25%
BSM 模型输入参数如表 1 所示。

表 1 BSM 模型输入参数

Tab. 1 Input parameters of BSM model

参数	数值
Soil Brightness(B)	0 ~ 0. 09
Soil spectral latitude(lat)/($^{\circ}$)	- 30 ~ 30
Soil spectral longitude(lon)/($^{\circ}$)	80 ~ 120
Soil moisture volume percentage(SM_p)	0 ~ 55

1. 5 光谱响应函数

由于 BSM 模型模拟的土壤光谱反射率是以 1 nm 为间隔的连续高光谱数据,而 Sentinel - 2 卫星的影像数据是 一定波长范围内多光谱数据,二者之间存在明显的尺度效应,因此需通过光谱响应函数将模拟的土壤高光谱反射率转换为对应 Sentinel - 2 各波段波长范围内多光谱数据,积分转换 R 公式为

$$R = \frac{\int_{i_{min}}^{i_{max}} f i R_{soil} di}{\int_{i_{min}}^{i_{max}} f i di} \tag{6}$$

式中 $i_{max} \setminus i_{min}$ ——不同波段最大、最小波长
 f ——Sentinel - 2 卫星光谱响应函数

1. 6 样本划分、模型构建与精度评价

1. 6. 1 样本划分

将各类土壤含水率按比例 2: 1 随机划分为建模集和验证集,对植被期划分土壤含水率等级后的土壤样本进行统计分析,结果如表 2 所示。

表 2 土壤含水率描述性统计

Tab. 2 Descriptive statistics of soil moisture content

数据集	样本数	最小值/%	最大值/%	平均值/%	标准差/%
总样本	172	10. 76	38. 56	15. 83	6. 100
建模集	121	10. 76	38. 93	15. 83	6. 090
验证集	51	10. 80	38. 93	15. 69	5. 406

1. 6. 2 堆叠模型

基于堆叠的土壤含水率回归模型旨在通过结合物理模型和经验模型的预测优化模型的鲁棒性和泛化能力,模型分为 2 层:①模型第 1 层:以 BSM 衍生 Sentinel - 2 反射率为输入、对应模型参数 SM_c 为输出对反演模型进行训练,进而利用实测 Sentinel - 2 反射率预测土壤含水率。②将第 1 层模型 SMC 预测值与 Sentinel - 1 的双极化波段和纹理特征作为第 2 层输入变量,以比例 2: 1 划分为训练集与验证

集,最终以实测 SMC 进行验证。
为了比较评估,采用 XGBoost、GBRT 和 AdaBoost 作为第 2 层的集成机器学习算法分别进行建模分析。XGBoost 通过加入正则化项优化损失函数,并应用二阶泰勒展开式提升模型的优化效率,同时支持多核并行处理,极大增强了模型的泛化性^[25]。GBRT 通过反复迭代的决策树处理数据,不仅适应性强,能处理各种类型的数据,还能有效避免过拟合问题^[26]。AdaBoost 算法通过不断调整数据样本的权重,并结合多个弱学习器形成 1 个强大的回归模型,适合处理小型数据集,展现出良好的适应性^[27]。
1. 6. 3 评价指标
采用决定系数(R^2)、均方根误差(RMSE)、平均绝对误差(MAE)进行模型的综合评价。当 R^2 越接近 1, RMSE 越接近 0, MAE 越接近 0 时,说明模型效果越好。
2 结果与分析
2. 1 BSM 模型参数率定及敏感性分析
2. 1. 1 参数率定
在 BSM 模型中,土壤形状参数 lat 和 lon 是描述土壤高光谱反射率曲线形态的关键变量。受地质背景、气候条件及人类活动等因素的综合影响,不同地区土壤具有明显差异的理化性质与类型,从而导致高光谱反射率特征存在显著空间分异。因此,在利用 BSM 模型模拟土壤高光谱反射率之前,必须对其参数范围进行系统、合理的界定。
由于 lat 和 lon 参数无法通过直接测量获取,本文采用 BSM 逆模型,以实测高光谱数据为基础,通过优化拟合反演得到对应的参数取值。BSM 模型拟合反射率与实测反射率之间具有较高的一致性,平均决定系数 R^2 达到 0. 944,表明反演结果具备优秀的精度。为进一步验证模型可靠性,随机选取 6 个不同采样日期的实测高光谱数据(ASD),与 BSM 拟合结果进行对比。如图 3 所示,在不同时期和条件下,模拟曲线与实测曲线均吻合良好,未出现明显系统性偏差,再次证明拟合精度较高、模型适用性较强。因此,通过逆模型反演率定 lat 和 lon 参数的方法有效可行,为基于 BSM 模型的研究区土壤高光谱反射率模拟及土壤水分等参数反演奠定了可靠基础。
如表 3 所示,通过实测土壤高光谱确定了 BSM 模型中土壤形状参数范围。参数 lat 和 lon 拟合结果如图 4 所示, lat 和 lon 具有良好的线性关系,决定系数 R^2 达到 0. 545。值得注意的是,本研究所使




图3 实测土壤高光谱与BSM拟合光谱结果

Fig. 3 Results of measured soil hyperspectral data and BSM fitted hyperspectral data

表3 BSM模型输入参数描述性统计

BSM model				
参数	最大值	最小值	平均值	中位数
lat	9.37	-14.37	-2.87	-2.09
lon	95.15	80.00	86.37	85.99




图4 参数lat和lon线性拟合

Fig. 4 Linear fitting of parameters lat and lon

用的高光谱数据均来自同一土壤类型,说明BSM形状参数在相同土壤理化性质中可能受到相同的光谱控制因子驱动。

2.1.2 敏感性分析

为系统探究土壤形状参数(lat、lon)及土壤含水率(SMC)对土壤光谱特性的影响,以-10°为初






图5 不同lat和lon设置下SMC变化对土壤光谱的影响

Fig. 5 Impact of SMC variations on soil spectral under different lat and lon settings

始值,以7.5°为步长依次设置lat参数,并依据既定线性关系同步调整lon参数,以模拟研究区域内不同空间位置的土壤状况。从图5可看出,在不同参数组合下,土壤含水率是影响光谱响应的主导因素。当lat与lon固定时,随SMC增大,土壤光谱在可见光至短波红外波段范围内反射率整体呈下降趋势,尤其在近红外与短波红外区域,由于水分吸收作用增强,反射率下降更为显著。另一方面,在相同SMC条件下,lat与lon增大虽对光谱形态产生一定影响,主要表现为可见光和近红外波段斜率出现不同程度降低,但整体变化幅度较小。这一现象反映研究区域内土壤类型相对均一、理化性质空间变异性较弱,进一步表明在设定参数范围内,土壤光谱曲线变化主要受土壤含水率影响,而土壤形状参数的变化并未引起显著的光谱响应差异。该结果凸显了SMC在光谱建模中重要性,也为区域尺度土壤含水率遥感反演参数敏感性分析提供了依据。

2.2 输入变量与土壤含水率相关性分析及土壤含水率堆叠反演模型构建

2.2.1 雷达后向散射系数及纹理特征与土壤含水率相关性分析

提取Sentinel-1数据的VV与VH2个极化波


段,并计算 8 种纹理特征,以分析其与 SMC 之间的相关性。如表 4 所示,Sentinel-1 的 VV 极化波段及其绝大多数纹理特征与 SMC 均呈显著相关关系,其中 VV 波段自身以及 VV_MEAN、VV_VAR、VV_CON、VV_DIS、VV_COR 等纹理特征均在 0.01 水平上显著相关。VH 极化波段及其纹理特征也普遍与 SMC 存在显著相关性,仅 VH_HOM、VH_ENT 和 VH_ASM 3 个特征未表现出显著相关关系。结果表明,Sentinel-1 雷达数据,特别是 VV 极化及相关纹理信息,对土壤含水率具有较强的指示能力,为融合多源遥感特征构建堆叠模型提供了可靠依据。

表 4 Sentinel-1 雷达后向散射系数及其纹理特征相关性分析

Tab.4 Correlation analysis of Sentinel-1 radar back scattering coefficient and its texture features

波段/特征	相关系数	波段/特征	相关系数
VV	-0.44 **	VH	-0.35 *
VV_MEAN	-0.36 **	VH_MEAN	-0.32 *
VV_VAR	-0.33 **	VH_VAR	-0.24 *
VV_HOM	-0.24 **	VH_HOM	0.12 *
VV_CON	0.42 *	VH_CON	0.33
VV_DIS	0.38 **	VH_DIS	0.16 *
VV_ENT	0.25 *	VH_ENT	0.21
VV_ASM	-0.24 *	VH_ASM	-0.26
VV_COR	-0.38 **	VH_COR	-0.19 **

注: * 表示在 $0.01 \leq P < 0.05$ 水平上显著, ** 表示 $P < 0.01$ 水平上显著。



2.2.2 土壤含水率堆叠反演模型第 1 层精度评价

基于率定参数后 BSM 模型生成了 10 000 条土壤高光谱反射率数据,并利用 Sentinel-2 卫星光谱响应函数转换为对应的多光谱波段数据,进而构建了以 BSM 衍生的模拟 Sentinel-2 多光谱数据与土壤含水率(SMC)为训练集反演模型。从图 6 可发现,BSM 参数率定后使 R^2 由 -1.143 提升至 0.368 , RMSE 从 7.935% 降至 4.323% ,MAE 从 5.661% 降至 2.758% 。然而,在实测 Sentinel-2 数据与同步测量真实 SMC 数据上验证结果表明,模型决定系数 R^2 为 0.368 ,RMSE 为 4.323% ,MAE 为 2.758% ,反演精度仍然较低,直接迁移能力有限。为进一步提升模型的性能与鲁棒性,构建了一种堆叠式建模框架。首先以 BSM 逆模型作为第 1 层,从光学遥感数据中提取土壤反射率特征;再引入第 2 层机器学习模型(如随机森林或梯度提升决策树),融合 Sentinel-1 雷达数据的后向散射系数及其纹理特征,联合对土壤含水率与多源遥感特征之间的复杂非线性关系进行建模与优化。该混合架构旨在充分发挥多源遥感数据的互补优势,增强模型在不同环境条件下泛化能力与反演精度。

2.2.3 土壤含水率堆叠反演模型第 2 层精度评价

在第 2 层模型中,将第 1 层预测结果与 Sentinel-1 的后向散射系数及其纹理特征进行融合,以比例 7:3 划分为训练集与验证集,通过 XGBoost、GRBT、




图 6 率定参数前后 BSM 模型测试集散点图

Fig.6 BSM model test distribution point diagrams

AdaBoost 3 种机器学习方法进分别建模。图 7 为第 2 层模型在验证集的预测性能,散点图中样本点相比于第 1 层模型更紧密地分布在 1:1 线两侧,表明预测值与实测值之间具有更高的一致性。在所有的机器学习模型中,AdaBoost 模型表现出更高的预测精度,验证集决定系数 R^2 达 0.816 ,RMSE 为 2.46% ,MAE 为 1.551% ,相比于 XGBoost 模型与 GBRT 模型 R^2 分别提升 0.066 和 0.116 ,RMSE 分别减小 0.402 、 0.677 个百分点,MAE 分别减小 0.789 、 0.258 个百分点。结果表明,引入 Sentinel-1 雷达

数据及其纹理特征有效增强了模型对土壤含水率的响应能力,特别是弥补光学数据在表面粗糙度影响的不足方面表现突出。

2.3 基于土壤含水率堆叠反演模型的研究区域 SMC 分布

基于土壤辐射传输模型与机器学习相结合的混合反演方法,实现新疆地区表层土壤含水率的高精度时空反演,结果如图 8 所示。

由图 8 可知,研究区内农田在该时期的土壤含水率为 $15\% \sim 20\%$,空间异质性明显。其中,临近




图7 3种集成学习模型测试集散点图

Fig. 7 Test set scatter diagrams of three integrated learning models




图8 研究区域土壤含水率分布

Fig. 8 Distribution of soil moisture content in study area during bare soil period

区域北部赤壁的农田及裸地土壤含水率较低,多数在15%以下,反映该区域水分条件相对匮乏,可能与地形、灌溉条件及土壤质地等因素有关。

从时间动态来看,4月中下旬与5月正值新疆裸土期或棉花苗期,普遍推行“控水促根”的科学灌溉策略,即在保障作物基本需水的前提下,通过适当控制灌溉频次与灌水量,以促进棉花根系下扎,增强抗旱能力。因此,该时期灌溉原则为“不早不灌”,灌溉总量较生长中后期显著减少。另一方面,随着气温逐步回升和棉花植株生长发育,作物蒸腾与地表蒸发均显著增强,土壤含水率耗散加剧,进一步影响了土壤含水率时空分布格局。

3 讨论

3.1 基于混合方法反演土壤含水率的优势

经验方法在土壤含水率预测领域发挥着关键作用,尤其是光学与雷达遥感数据的协同应用,能够有效结合地表反射特性与土壤介电/粗糙度信息,提供多样化、互补的特征参数,从而大幅提升模型的预测精度和区域适用性^[28]。然而,目前大多研究仍聚焦于通过经验模型融合多源遥感数据反演土壤含水率,过于依赖统计关系,对反射率与后向散射等观测

信号背后的物理机制融合不足,缺少模型在各地区的适用性与可移植性,导致模型在跨区域、跨时相应用时泛化能力受限,且可解释性较弱^[29]。

本研究提出的辐射传输模型与机器学习相结合的混合反演方法,在提升土壤含水率反演精度与机理可解释性方面表现出显著优势。BSM模型基于水膜涂层方法,将GSV模型进行改进,通过将湿土视为覆盖有薄水层的干燥土层系统模拟湿土的高光谱反射率,具有较强的物理基础,能够清晰描述光在视图中传输路径,有效弥补了纯经验模型在物理机制阐述方面的不足。然而,该模型对土壤粗糙度、空间异质性及大田环境中复杂因素考虑有限,导致在直接应用于真实遥感场景时反演精度受限。

为克服这一局限,引入Sentinel-1卫星的雷达后向散射系数及其纹理特征。雷达信号对土壤介电特性和地表粗糙度极为敏感,能够在光学数据之外提供独立的土壤水分响应信息^[30]。通过融合雷达信息及其纹理特征,增强模型在大田环境下对空间异质性和土壤粗糙度编译的描述能力,有效补充了BSM模型在大田环境下适用性和稳健性。从表5可看出,BSM+AdaBoost方法相比于其他建模方法精度最高, R^2 为0.816,证实了混合建模框架能够充

分发挥物理模型与数据驱动方法各自的优势。BSM 模型提供了可解释的光学响应机理,而集成机器学习方法则通过融合多源遥感数据,捕捉非线性 and 复杂环境因素的影响,从而在保持物理意义的前提下,显著提升了区域尺度 SMC 反演的精度与鲁棒性。

表 5 不同模型反演土壤含水率评价指标
Tab. 5 Evaluation index of soil moisture content retrieved by different models

模型	R^2	RMSE/%	MAE/%
RF	0.547	5.156	2.870
SVM	0.258	6.600	4.295
PLSR	0.302	6.398	3.935
XGBoost	0.607	4.804	2.609
AdaBoost	0.641	4.587	2.536
GBRT	0.596	4.867	2.931
BSM + AdaBoost	0.816	2.460	1.551

机器学习算法具有强大的多维特征挖掘与非线性拟合能力,能够有效融合物理模型与多源遥感特征,因此选择合适的建模方法尤为关键。以往研究广泛采用 ELM、SVM、BPNN 和 RF 方法对不同数据源进行融合,其中 RF 因集成多棵决策树,鲁棒性强、适应性高且不易过拟合,融合模型预测精度往往优于其他单一模型。然而,传统机器学习方法在大规模数据并行计算、特征变量数量与多重共线性处理方面存在一定局限,通常需要在建模前进行特征筛选或降维。与此相比,集成学习方法能够通过组合多个基学习器,有效降低对特征共线性的敏感度,并可并行融合来自不同传感器和尺度的特征信息。

将基于辐射传输理论 BSM 模型输出的光学特征参数,与 Sentinel-1 雷达后向散射系数及其纹理特征,以及地形和气象等环境因子相结合,构建多源特征集,并分别采用 AdaBoost、GBRT 和 XGBoost 集成学习算法建立混合反演模型。结果表明,在优化的特征组合下,3 种集成模型均表现出较高的精度与稳健性,有效提升了 BSM 模型在真实大田条件下适用性。已有研究(如 Das 等^[31])通过引入异构集成学习方法,证明集成策略能够在一定程度上克服单一模型泛化能力不足的问题。Azizi 等^[32]提出的堆叠集成方法,也在多种土壤属性预测中表现出高于单一模型的性能。本研究进一步验证了通过将物理机制明确的 BSM 反演结果与多源遥感特征输入集成学习框架,不仅保留了模型的可解释性,而且显著增强了对土壤空间异质性、粗糙度以及植被覆盖干扰的抵御能力,从而为干旱与半干旱地区区域尺度 SMC 监测提供了高精度、可推广的技术路径。

3.2 BSM 模型参数率定对堆叠模型影响

BSM 模型参数率定集中于从 GSV 模型继承的

亮度 B 以及光谱形状参数 lat 与 lon 。二者本质上并不直接映射到某一物理光谱吸收特征,而是将 GSV 模型中 3 条“基光谱”映射到全球任意干土土壤高光谱曲线中,以反映土壤成分、结构及其他稳定的理化性质^[10]。在 GSV 模型中,形状参数一经确定,通常在相同土样条件下保持稳定,不随土壤含水率变化而改变。

然而,当通过光谱响应函数将实际高光谱数据转换为卫星多光谱数据时,利用 BSM 模型反演土壤含水率过程,不同地区的土壤样本在光谱表现上可能大不相同,同时数据源的不同或样品表面状态变化会导致 lat 和 lon 偏离土壤在干土特征空间中真实位置,导致 BSM 模型“干土基准”失真,进而使水膜涂层方法在计算含水吸收效应时建立在错误基准之上。这种失真在训练集内可能通过模型自由度拟合局部误差,但在验证集(图 6a)中可看出,由于基准差异累积,出现 $R^2 < 0$ 情况,即模型比训练集均值预测还差。

在引入基于实测土壤高光谱数据对 lat 、 lon 参数范围约束后,显著缓解了上述问题。限制后的参数不仅更接近真实土壤在干土特征空间中位置,也减少了训练集中对于脱离实际研究区域土壤类型的土壤光谱训练,使得在土壤含水率预测中,可以使用预训练的模型在卫星多光谱数据中检索土壤含水率。这一调整使 R^2 由 -1.143 提升至 0.368 ,RMSE 从 7.935% 降至 4.323% ,MAE 从 5.661% 降至 2.758% 。结果表明,尽管 lat 、 lon 无直接物理量纲,但合理性直接影响 BSM 模型的土壤含水率反演性能。

在机制层面, lat 、 lon 物理意义有限并不意味着可以任意波动。事实上,在 GSV 模型空间中确定了“干土原型”的光谱全貌,而这一原型是水膜涂层方法计算的起点。当 lat 、 lon 被保持在合理区间时,BSM 模型在不同土壤类型和外界条件下表现出更高的泛化能力和稳定性。未来研究可以尝试结合土壤类型分布信息,对 lat 、 lon 先验分布进行分类绑定,从而在堆叠融合中进一步抑制来自 GSV 基准漂移的误差传递,提高模型在跨区域、跨传感器数据集上普适性。

3.3 本文方法创新性与可移植性

本研究在土壤含水率遥感反演中提出了一种创新性的混合建模方法,通过将改进的 BSM 辐射传输模型与集成学习框架相结合,实现了物理机理引导的机器学习建模。相较于单纯依赖光学指数或经验统计关系的传统方法,所提出的混合建模框架在理论上具备迁移至其他区域的潜力,因为 BSM 辐射传输模型本身基于物理机制构建,参数不受特定地域限制,可直接测量获得,从而使模型能够克服在不同

地区、不同土壤性质条件下模型精度不足与可解释性较弱的问题。

具体而言,BSM 模型通过水膜涂层的方式改进 GSV 模型,将湿土视为“薄水层覆盖的干燥土壤体系”,从而准确模拟湿土高光谱反射率,并建立清晰的物理传输路径。在此基础上,引入 Sentinel-1 SAR 数据的后向散射系数及纹理特征,增强模型对土壤介电特性与地表粗糙度的刻画能力,并有效量化植被覆盖对微波信号的影响。多源数据特征经归一化与参数化处理后,输入到 AdaBoost、GBRT 和 XGBoost 集成学习算法中,形成基于物理机理约束的混合反演框架。

在区域尺度验证中,利用分辨率 20 m Sentinel-1/2 协同数据实现了农田土壤含水率的动态制图,结果表明在裸土期空间异质性强的环境下仍能保持较高精度与稳健性。与已有研究相似,如 Das 等^[31]提出的异构集成方法、Azizi 等^[32]提出的堆叠集成方法等,本研究进一步验证了集成策略在克服单一模型泛化性不足方面的优势。不同之处在于,本研究强调了物理模型输出与机器学习特征的深度融合,使得混合模型不仅具备可解释性,而且具备较强的跨区域应用潜力。

在可移植性方面,本研究的关键输入参数可依托全球已有产品与数据库(如 MODIS LAI、SoilGrids 等)获取,降低了对实地测量的依赖。同时能够兼容多源遥感数据,包括 Landsat-8/9、Sentinel-2 等光学观测^[33],以及 ALOS-2 PALSAR^[34]、NISAR^[35]等微波数据,确保了在不同地区和数据条件下适用性与推广性。总体而言,本文方法为干旱与半干旱区的土壤含水率监测提供了可扩展、可解释且高精度的技术途径。

3.4 不足与展望

通过 BSM 土壤辐射传输模型堆叠集成学习框架主要集中于非植被覆盖条件下土壤含水率反演,而在植被覆盖期的土壤含水率反演仍存在一定挑战。在植被覆盖较强的区域,植被水分含量和生物量对遥感信号的影响较大,现有模型在这种情况下表现相对较弱^[36]。但目前研究表明,土壤辐射传输模型能够与冠层辐射传输模型相结合,通过解析光在叶片和土壤之间的传播路径,能够更精确地模拟植被对土壤表面辐射特性的影响。通过这种耦合模型,可以更好地识别植被层与土壤之间的相互作用,并考虑到光线在冠层和土壤表面之间的多次散射、反射与吸收过程^[10]。这一方法不仅提高了土壤含水率反演的准确性,尤其在植被覆盖区域,还能有效地降低植被对遥感信号的干扰,使土壤含水率的反

演结果更加可靠。未来研究可进一步优化耦合模型,考虑不同植被类型和生长阶段对土壤含水率的影响,提升在复杂环境下反演能力。

尽管 BSM 模型在土壤光谱特性反演上具有较强的物理基础,但在实际应用过程,仍需要依赖当地实测的土壤高光谱数据,以确定当地的土壤类型。这是因为不同地区的土壤具有不同的光谱特征和物理性质,这些差异直接影响模型参数的适用性和精度。因此,为了确保 BSM 模型参数能够在特定区域内得到合理的取值范围和准确的校正,必须通过实地采集高光谱数据识别和表征当地土壤的光谱特征,使模型能更精确地反映土壤实际物理属性,进而提高土壤含水率反演结果的可靠性与准确性。同时,实地采集的高光谱数据也可以通过星载或机载高光谱数据替代,以此对 BSM 模型参数率定,但相比于地面测量,精度期望可能相对较低。此外,实测数据也有助于调整模型中土壤形状参数,使 BSM 模型在不同土壤类型和环境条件下适用性得到更好的优化。

因此,在不同生育期、不同土壤类型条件下反演土壤含水率时,未来应着重探索土壤辐射传输模型与冠层、大气等辐射传输模型相结合,通过探索光在不同介质中传播过程,结合卫星遥感反演的时空覆盖优势与遥感机理的描述能力,提升土壤含水率检测系统的可靠性与泛用性。同时,增加地面传感器网络设置,并结合已有的国家或全球土壤光谱库自动推导出适合不同地区的参数设置范围,在不同土壤类型下实现稳定、精准的反演土壤含水率。

4 结论

(1) 提出了一种融合土壤辐射传输模型与集成学习的堆叠模型,利用多源遥感数据反演土壤含水率,充分利用光学与雷达的优势、经验模型与基于物理的模型的特性的互补,为干旱区农业水资源管理提供了新的技术手段。

(2) 基于地面实测高光谱数据,通过 BSM 模型成功率定了研究区内土壤光谱形状参数(lat,lon)的有效范围。结果表明,BSM 模型对土壤高光谱的拟合精度高($R^2 = 0.944$),且参数 lat 与 lon 之间存在显著的线性关系($R^2 = 0.545$)。率定过程为 BSM 模型赋予了可量化的参数基础,确保了模拟 Sentinel-2 反射率数据更符合区域土壤特性,为堆叠模型第 1 层构建提供了关键的物理约束和可靠的输入。

(3) 融合 Sentinel-1 雷达后向散射系数及其纹理特征后,堆叠模型反演精度显著提升。在 3 种集成学习算法中,AdaBoost 模型表现最优,验证集 R^2 达到 0.816, RMSE 和 MAE 分别为 2.460% 和

1.551%。表明雷达数据能够有效弥补光学模型在表征土壤粗糙度和介电特性方面的不足,凸显了多源遥感协同反演在实际农田环境中优势。

(4) 构建的土壤含水率混合反演模型,有效耦合了 BSM 辐射传输模型与集成学习算法,充分发挥了光学模型在描述水分光谱响应机理上的优势,以及雷达数据在捕捉土壤介电特性与粗糙度方面的特长。模型显著提升了 SMC 反演精度与稳健性($R^2 = 0.816$),为干旱区农业水分管理与干旱监测提供了一种兼具物理可解释性与高精度的新技术途径。该策略有效证明了混合模型在克服单一模型局限、提升区域尺度遥感反演能力方面的巨大潜力。

参 考 文 献

[1] Faiz M A, Zhang L, Liu D, et al. Soil moisture and ecosystem vegetation health effects on drought severity[J]. Journal of Advanced Research, 2026, 82: 59 – 71.

[2] Romano N. Soil moisture at local scale: measurements and simulations[J]. Journal of Hydrology, 2014, 516: 6 – 20.

[3] Taghadosi M M, Hasanlou M, Eftekhari K. Soil salinity mapping using dual-polarized SAR Sentinel – 1 imagery [J]. International Journal of Remote Sensing, 2019, 40(1): 237 – 252.

[4] Mu T, Liu G, Yang X, et al. Soil-moisture estimation based on multiple-source remote-sensing images[J]. Remote Sensing, 2023, 15(1): 139.

[5] Meng Q, Xie Q, Wang C, et al. A fusion approach of the improved dubois model and best canopy water retrieval models to retrieve soil moisture through all maize growth stages from Radarsat – 2 and Landsat – 8 data[J]. Environmental Earth Sciences, 2016, 75(20): 1377.

[6] Liu Y, Qian J, Yue H. Combined Sentinel – 1A with Sentinel – 2A to estimate soil moisture in farmland[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 1292 – 1310.

[7] Guo F, Huang Z, Su X, et al. Soil moisture content inversion model on the basis of Sentinel multispectral and Radar Satellite remote sensing data[J]. Journal of Soil Science and Plant Nutrition, 2024, 24(4): 7919 – 7933.

[8] 张智韬, 贺玉洁, 殷皓原, 等. 基于 Sentinel – 1/2 改进极化指数和纹理特征的土壤盐分反演[J]. 农业机械学报, 2024, 55(1): 175 – 185.

Zhang Zhitao, He Yujie, Yin Haoyuan, et al. Synergistic estimation of soil salinity based on Sentinel – 1/2 improved polarization combination index and texture features[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 175 – 185. (in Chinese)

[9] Doepper V, Rocha A D, Berger K, et al. Estimating soil moisture content under grassland with hyperspectral data using radiative transfer modelling and machine learning[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 110: 102817.

[10] Yang P, Van Der T C, Yin T, et al. The SPART model: a soil-plant-atmosphere radiative transfer model for satellite measurements in the solar spectrum[J]. Remote Sensing of Environment, 2020, 247: 111870.

[11] Babellet A, Vu P V H, Jacquemoud S, et al. Marmit: a multilayer radiative transfer model of soil reflectance to estimate surface soil moisture content in the solar domain (400 ~ 2 500 nm) [J]. Remote Sensing of Environment, 2018, 217: 1 – 17.

[12] Jiang C, Fang H. GSV: a general model for hyperspectral soil reflectance simulation[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 83: 101932.

[13] Amazirh A, Merlin O, Er-Raki S, et al. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel – 1 radar and Landsat thermal data: a study case over bare soil[J]. Remote Sensing of Environment, 2018, 211: 321 – 337.

[14] 周美玲, 张德宁, 王浩, 等. 光学和微波遥感数据联合反演植被覆盖表层土壤含水率[J]. 灌溉排水学报, 2024, 43(1): 45 – 51.

Zhou Meiling, Zhang Dening, Wang Hao, et al. Inversion of surface soil moisture under vegetated areas based on optical and microwave remote sensing data[J]. Journal of Irrigation and Drainage, 2024, 43(1): 45 – 51. (in Chinese)

[15] Yang H, Song J, Teng Y, et al. Coupling model-driven and data-driven methods for estimating soil moisture over bare surfaces with Sentinel – 1A dual-polarized data [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 4820 – 4832.

[16] Adab H, Morbidelli R, Saltalippi C, et al. Machine learning to estimate surface soil moisture from remote sensing data[J]. Water, 2020, 12(11): 3223.

[17] Du R, Chen J, Xiang Y, et al. Timely monitoring of soil water-salt dynamics within cropland by hybrid spectral unmixing and machine learning models[J]. International Soil and Water Conservation Research, 2024, 12(3): 726 – 740.

[18] Taghizadeh-Mehrjardi R, Schmidt K, Amirian-Chakan A, et al. Improving the spatial prediction of soil organic carbon content in two contrasting climatic regions by stacking machine learning models and rescanning covariate space[J]. Remote Sensing, 2020, 12(7): 1095.

[19] 巴亚岚, 张智韬, 谢坪良, 等. 集成 Sentinel – 1/2 和环境变量的新疆农田土壤含盐量反演[J]. 农业工程学报, 2024, 40(16): 171 – 179.

Ba Yalan, Zhang Zhitao, Xie Pingliang, et al. Inverting soil salinity of farmland in Xinjiang by integrating Sentinel – 1/2 and environmental variables[J]. Transactions of the CSAE, 2024, 40(16): 171 – 179. (in Chinese)

[20] Sun M, Yang Y, Li S, et al. A study on hyperspectral soil total nitrogen inversion using a hybrid deep learning model CBiResNet – BiLSTM[J]. Chemical and Biological Technologies in Agriculture, 2024, 11(1): 157.

- imagery[J/OL]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2023. <https://doi.org/10.5194/isprs-annals-X-4-W1-2022-49-2023>.
- [23] Wang Y, Qu Z, Yang W, et al. Inversion of soil salinity in the irrigated region along the southern bank of the Yellow River using UAV multispectral remote sensing[J]. *Agronomy*, 2024, 14(3): 523.
- [24] Hu J, Peng J, Zhou Y, et al. Quantitative estimation of soil salinity using UAV-borne hyperspectral and satellite multispectral images[J]. *Remote Sensing*, 2019, 11(7): 736.
- [25] 张智韬,魏广飞,姚志华,等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. *农业机械学报*, 2019, 50(12): 151–160.
- Zhang Zhitao, Wei Guangfei, Yao Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(12): 151–160. (in Chinese)
- [26] Zhai J, Wang N, Hu B, et al. Estimation of soil salinity by combining spectral and texture information from UAV multispectral images in the Tarim River Basin, China[J]. *Remote Sensing*, 2024, 16(19): 3671.
- [27] Mzid N, Boussadia O, Albrizio R, et al. Salinity properties retrieval from Sentinel-2 satellite data and machine learning algorithms[J]. *Agronomy*, 2023, 13(3): 716.
- [28] Li Y, Chang C, Wang Z, et al. Upscaling remote sensing inversion and dynamic monitoring of soil salinization in the Yellow River Delta, China[J]. *Ecological Indicators*, 2023, 148: 110087.
- [29] Mohamed S A, Metwaly M M, Metwalli M R, et al. Integrating active and passive remote sensing data for mapping soil salinity using machine learning and feature selection approaches in arid regions[J]. *Remote Sensing*, 2023, 15(7): 1751.
- [30] He Y, Zhang Z, Xiang R, et al. Monitoring salinity in bare soil based on Sentinel-1/2 image fusion and machine learning[J]. *Infrared Physics & Technology*, 2023, 131: 104656.

(上接第 93 页)

- [21] Ma G, Ding J, Han L, et al. Digital mapping of soil salinization based on Sentinel-1 and Sentinel-2 data combined with machine learning algorithms[J]. *Regional Sustainability*, 2021, 2(2): 177–188.
- [22] Duan M, Song X, Liu X, et al. Mapping the soil types combining multi-temporal remote sensing data with texture features[J]. *Computers and Electronics in Agriculture*, 2022, 200: 107230.
- [23] 刘浩, 杨锡震, 张蓓, 等. 基于分数阶微分光谱指数的冬小麦根域土壤含水率估算模型[J]. *农业工程学报*, 2023, 39(13): 131–140.
- Liu Hao, Yang Xizhen, Zhang Bei, et al. Estimation model of soil moisture content in root domain of winter wheat using a fractional-order differential spectral index[J]. *Transactions of the CSAE*, 2023, 39(13): 131–140. (in Chinese)
- [24] Ångström A. The albedo of various surfaces of ground[J]. *Geografiska Annaler*, 1925, 7(4): 323–342.
- [25] Sheridan R P, Wang W M, Liaw A, et al. Extreme gradient boosting as a method for quantitative structure-activity relationships[J]. *Journal of Chemical Information and Modeling*, 2016, 56(12): 2353–2360.
- [26] Wang L, Zhang Y, Yao Y, et al. GBRT-based estimation of terrestrial latent heat flux in the Haihe River Basin from satellite and reanalysis datasets[J]. *Remote Sensing*, 2021, 13(6): 1054.
- [27] Bartlett P L, Traskin M. AdaBoost is consistent[J]. *Journal of Machine Learning Research*, 2007, 8: 2347–2368.
- [28] Prakash R, Singh D, Pathak N P. A fusion approach to retrieve soil moisture with SAR and optical data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(1): 196–206.
- [29] Li S, Zhu P, Song N, et al. Regional soil moisture estimation leveraging multi-source data fusion and automated machine learning[J]. *Remote Sensing*, 2025, 17(5): 837.
- [30] Wang J, Ding J L, Chen W Q, et al. Microwave modeling of soil moisture in oasis regional scale based on Sentinel-1 radar images[J]. *Journal of Infrared and Millimeter Waves*, 2017, 36(1): 120–126.
- [31] Das A, Bhattacharya B K, Setia R, et al. A novel method for detecting soil salinity using AVIRIS-NG imaging spectroscopy and ensemble machine learning[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 200: 191–212.
- [32] Azizi K, Garosi Y, Ayoubi S, et al. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran[J]. *Soil and Tillage Research*, 2023, 229: 105681.
- [33] Shokati H, Mashal M, Noroozi A, et al. Random forest-based soil moisture estimation using Sentinel-2, Landsat-8/9, and UAV-based hyperspectral data[J]. *Remote Sensing*, 2024, 16(11): 1962.
- [34] Zribi M, Muddu S, Bousbih S, et al. Analysis of L-Band SAR data for soil moisture estimations over agricultural areas in the tropics[J]. *Remote Sensing*, 2019, 11(9): 1122.
- [35] Lal P, Singh G, Das N N, et al. A multi-scale algorithm for the NISAR mission high-resolution soil moisture product[J]. *Remote Sensing of Environment*, 2023, 295: 113667.
- [36] 周鹏, 丁建丽, 王飞, 等. 植被覆盖地表土壤水分遥感反演[J]. *遥感学报*, 2010, 14(5): 966–981.
- Zhou Peng, Ding Jianli, Wang Fei, et al. Retrieval methods of soil water content in vegetation covering areas based on multi-source remote sensing data[J]. *Journal of Remote Sensing*, 2010, 14(5): 966–981. (in Chinese)