

DOI: 10.11766/trxb202204110167

郑曼迪, 刘忠, 许昭辉, 李剑辉, 孙君龄. 基于微波遥感的土壤水分反演估算研究进展[J]. 土壤学报, 2024, 61 (1): 16–28.

ZHENG Mandi, LIU Zhong, XU Zhaohui, LI Jianhui, SUN Junling. Research Progress of Soil Moisture Estimation Based on Microwave Remote Sensing[J]. Acta Pedologica Sinica, 2024, 61 (1): 16–28.

基于微波遥感的土壤水分反演估算研究进展*

郑曼迪^{1, 2}, 刘忠^{1, 2†}, 许昭辉^{1, 2}, 李剑辉^{1, 2}, 孙君龄^{1, 2}

(1. 中国农业大学土地科学与技术学院, 北京 100193; 2. 农业农村部华北耕地保育重点实验室, 北京 100193)

摘要: 土壤水分是地表和大气水热过程交换的重要纽带, 对于农业生产、生态规划、水资源管理等具有十分重要的意义。微波遥感具有基本不受天气条件影响, 具有较好探测植被覆盖下的土壤信息和土壤水分变化趋势等优势, 成为目前遥感精确反演土壤水分的热点。本文整理了现有全球尺度的基于微波遥感的土壤水分产品; 分析比较了土壤水分反演中主动微波遥感、被动微波遥感、主被动微波协同技术的原理、特点、适用范围和关键技术进展: 主动微波遥感和被动微波遥感的优势分别在于高空间分辨率和高时间分辨率, 高空间分辨率可以很好捕捉地表细微的空间信息特征, 但囿于土壤水分与后向散射系数之间的复杂关系, 特别是植被、地表粗糙度等对雷达后向散射系数的干扰, 使得反演土壤水分的精度不高, 因而根据现实情况选取不同散射模型以及利用多源数据协同是目前改善精度的研究热点。而高时间分辨率可以实现全球及大尺度下的土壤水分监测, 但是很难满足小尺度或者小区域范围的实际研究需求, 为了能使实测数据在空间上得以较好匹配, 提出多种降尺度方法。结合以上两种微波遥感方式的优劣, 依托更为丰富的数据源、相对成熟的观测技术来对两者进行融合以提取更多的水分信息, 以提升反演精度或者获得长时间序列数据。在目前的方法中, 土壤水分反演在小尺度下表现出良好的性能, 但在全球尺度上会出现数据缺失、适用性不强、反演精度不高以及反演过程过于复杂等诸多问题, 可以借助多种观测方式(多极化、多角度、多波段)、多时相重复观测、在原有模型上引入新的算法以及数据同化等方面着手进行改进, 同时全球卫星导航系统(Global Navigation Satellite System, GNSS)中长期稳定、高时空分辨率的 L 波段微波信号在陆面遥感领域的快速发展也为我国北斗卫星导航系统(BeiDou Navigation Satellite System, BDS)的发展提供了借鉴, 展现出在土壤水分反演方面的巨大潜力。

关键词: 主被动微波遥感; 散射方式; 降尺度; GNSS-R

中图分类号: K903 **文献标志码:** A

Research Progress of Soil Moisture Estimation Based on Microwave Remote Sensing

ZHENG Mandi^{1, 2}, LIU Zhong^{1, 2†}, XU Zhaohui^{1, 2}, LI Jianhui^{1, 2}, SUN Junling^{1, 2}

(1. College of Land Science and Technology, China Agricultural University, Beijing 100193, China; 2. Key Laboratory of Arable Land Conservation (North China), Ministry of Agriculture and Rural Affairs, Beijing 100193, China)

* 国家重点研发计划项目(2022YFD1500701)资助 Supported by the National Key Research and Development Program of China (No. 2022YFD1500701)

† 通讯作者 Corresponding author, E-mail: lzh@cau.edu.cn

作者简介: 郑曼迪(1993—), 女, 博士研究生, 主要从事农业遥感应用研究。E-mail: mandy0719zheng@163.com

收稿日期: 2022-04-11; 收到修改稿日期: 2022-07-06; 网络首发日期(www.cnki.net): 2023-05-15

Abstract: Soil moisture is an important link for the exchange of water and heat processes between the surface and the atmosphere, and is of great significance to agricultural production, ecological planning, and water resources management. Microwave remote sensing has the advantages of not being affected by weather conditions and being able to better detect the soil information and trend of soil moisture change under vegetation coverage. Thus, it is a hot spot for accurate soil moisture retrieval by remote sensing. With the gradual increase in the number of Earth observation satellites, microwave detectors have developed from C-band to L-band, and soil moisture datasets have become more and more abundant. In this paper, the existing global-scale soil moisture products based on microwave remote sensing are summarized. It also analyzes and compares the principle, characteristics, application scope and key technological progress of active microwave remote sensing, passive microwave remote sensing, and active and passive microwave fusion in soil moisture retrieval. The advantage of active microwave remote sensing and passive microwave remote sensing is high spatial resolution and high temporal resolution, respectively. High spatial resolution can capture the subtle spatial information features of the surface, but it is limited by the complex relationship between soil moisture and backscattering coefficients, especially the interference of vegetation and surface roughness on the radar backscattering coefficient making retrieval of soil moisture inaccurate. Therefore, selecting different scattering models according to the actual situation and using multi-source data synergy are the current research hotspots to improve accuracy. This paper summarizes the active microwave soil moisture retrieval method into three types: mechanism model, empirical model and semi-empirical model according to the principle. We also considered the applicability and shortcomings at the same time. For instance, high temporal resolution can achieve global and large-scale soil moisture monitoring, but it is difficult to meet the actual research needs of small-scale or small-scale areas. In order to better match the measured data in space, four downscaling methods based on the geostatistical method, mathematical statistics method, data assimilation method and multi-source remote sensing data fusion method are proposed. Combining the advantages and disadvantages of the above two microwave remote sensing methods, researchers can rely on more abundant data sources and relatively mature observation technology to fuse and extract more moisture information and to improve the retrieval accuracy or obtain long-term series data. However, this method often has the problem of missing data due to factors such as revisit time, seasonal ice period or radio frequency interference, which has a great impact on the spatiotemporal continuity of the data. So, the interpolation methods based on time, space, and statistics have been employed to solve the missing value issues. In the current method, soil moisture retrieval shows good performance at small scales, but at the global scale, there will be many problems such as missing data, poor applicability, low retrieval accuracy, and too complicated retrieval processes. Improvements can be made by employing multiple observation methods (multi-polarization, multi-angle, multi-band), multi-temporal repeated observation, the introduction of new algorithms on the original model and data assimilation. The rapid development of long-term stable and high spatiotemporal resolution L-band microwave signals in the field of land remote sensing of Global Navigation Satellite System also provides a reference for the development of China's BeiDou Navigation Satellite System, showing its huge application potential.

Key words: Active and passive microwave remote sensing; Scattering mode; Downscaling; GNSS-R

土壤水在陆面与大气中水热交换过程中发挥着重要作用，也是地球生态系统中植被更替及土壤碳循环的重要控制因素^[1-2]。土壤水分作为气候变化的敏感因子，通过改变地表反射率、地表蒸散发过程及潜热、显热形式的能量输送过程对气候变化产生显著影响^[3]。土壤水时空动态在气候变化、农业可持续性发展、水资源高效管理、自然灾害（洪水、干旱、滑坡等）监测等方面具有重要的应用价值。由于土壤水分直接影响作物生长发育，因此大面积、快速、准确地估算耕地土壤水分将有助于作物长势

监测、产量预算等农业生产管理^[4]。

常规的土壤水分监测方法，主要有烘干称重法、中子仪法、时域反射仪法和频域反射仪法等，这些方法具有时空分辨率低、成本高、工作效率低等缺点^[5]。实测数据无法反映空间大尺度连续的变化规律，而遥感是大面积精确估计土壤水分的关键手段，其多时相、多波段的特征对于空间大尺度土壤水分时空特征的研究具有重要意义。

基于遥感的土壤水分反演基本可分为两大类，即基于可见光至近红外波段数据的反演和基于微波

雷达数据的反演。可见光至近红外遥感拥有较高空间分辨率，其中的热惯量法适合裸土和低植被覆盖区，难以大范围运用于植被茂密的区域；而基于光谱指数或特征空间的方法在特定研究区域反演结果精度较高，但存在部分参数计算复杂，泛化性较差等问题。微波遥感不受光照、云雾等天气条件的限制，对云有较强的穿透能力，能够探测植被覆盖下的土壤信息，具有全天候的模拟能力和对土壤水分变化的高敏感性，使微波遥感反演土壤水分研究得以广泛应用。

目前关于微波遥感反演土壤水分的综述年份较早，缺少对近年来在遥感技术、数据源和反演模型快速发展的总结性文章，急需总结最新的研究进展，对模型的异同以及适用性范围进行对比和凝练。基于此，本文首先总结目前基于微波探测器的土壤水分产品的特点，之后对主动微波遥感、被动微波遥感、主被动微波协同反演的优缺点以及适用范围进行梳理，最后对土壤水分微波反演的研究前景提出展望。

1 全球尺度土壤水分数据产品

微波遥感监测土壤水分分为被动微波遥感和主动微波遥感两种方式，被动微波是基于微波辐射计探测地物辐射亮温来实现土壤水分的反演，支持区

域、全球等大尺度土壤水分时空特征研究，主动微波是通过传感器向探测目标主动发射微波信号并接收其与目标作用后的后向散射信号，形成遥感数字图像（图 1），目前使用的传感器主要为合成孔径雷达（Synthetic Aperture Radar, SAR）。

随着对地观测卫星的数量逐渐增加，微波探测器从 C 波段发展到了 L 波段，土壤水分数据集越来越丰富（表 1），目前常用的被动微波卫星及微波辐射计有 AMSR-E、AMSE-2、SMOS、SMAP 和 SSM/I 等。主动微波传感器则通过传感器发射电磁波并接收目标地物回波信号实现，具备高空间分辨率的优势，常用的搭载主动微波传感器的卫星有 ENVISAT/ASAR、RadarSat、ASCAT、Sentinel-1 及我国的高分三号（GF-3）等。

2 土壤水分微波反演方法

2.1 主动微波遥感反演

土壤在微波波段的发射和散射特性均受到其介电特性的影响，而土壤介电常数又与土壤水分的大小直接相关，这是微波遥感反演土壤水分的物理基础^[6]。主动微波遥感中的合成孔径雷达具有高空间分辨率，能够捕捉细微的地表空间信息特征。除了




图 1 主被动微波遥感工作示意图

Fig.1 Schematic diagram of active and passive microwave remote sensing

表 1 全球微波遥感土壤水分产品及搭载卫星特征

Table 1 Comparative characteristics of global microwave remote sensing soil moisture products and carried satellites

卫星及搭载仪器 Satellite & Instrument	波段 Band	发射国家/机构 Launching state and institution	时间分辨率 Temporal resolution	空间分辨率 Spatial resolution	时间序列 Time series
ASCAT ^①	主动微波 C 波段 (5.255 GHz)	ESA ^⑧	3 d	12~25 km	2007 年至今
AMSE-E/2 ^②	被动微波多波段 (6.93~8.9 GHz)	JAXA ^⑨	1~3 d	25 km	AMSE-E: 2002—2010 年 AMSE-2: 2013 年至今
SMOS ^③	被动微波 L 波段 (1.4 GHz)	NASA ^⑩	1~3 d	35 km	2010 年至今
SMAP ^④	被动微波 L 波段 (1.2~1.4 GHz)	NASA ^⑩	3 d	3~40 km	2015 年至今
FY-3 ^⑤	被动微波 L 波段 (10.65 GHz)	CNSA ^⑪	1~3 d	25 km	2013 年至今
Sentinel-1 ^⑥	主动微波 C 波段 (5.4 GHz)	ESA ^⑧	6 d	5 m×20 m	2014 年至今
GF-3 ^⑦	主动微波 C 波段 (5.4 GHz)	CNSA ^⑪	2~3 d	1~500 m	2016 年至今

①Advanced Scatterometer, 高级散射计; ②Advanced Microwave Scanning Radiometer-E/2, 高级微波扫描辐射计; ③ Soil Moisture and Ocean Salinity, 土壤水分和海洋盐度卫星; ④Soil Moisture Active/Passive, 土壤水分主被动探测计划; ⑤Fengyun-3, 风云三号气象卫星; ⑥Sentinel-1, 哨兵一号卫星; ⑦ Gaofeng-3, 高分三号卫星; ⑧ European Space Agency, 欧洲航天局; ⑨ Japan Aerospace Exploration Agency, 日本宇宙航空研究开发机构; ⑩ National Aeronautics and Space Administration, 美国国家航空航天局; ⑪ China National Space Administration, 中国国家航天局。

受土壤介电特性控制外, 主动微波观测的后向散射信号还与地表的几何结构(如粗糙度)和植被覆盖密切相关。由于地物与雷达散射之间的相互作用复杂、散射机理混杂(面散射、体散射以及二面角散射相互混合), 所以如何提高基于 SAR 反演土壤水分的精度一直是研究的热点和难点。

主动微波雷达的土壤水分反演方法根据原理大致分为机理模型、经验模型以及半经验模型三种。机理模型是以辐射传输理论为基础进行建模, 是目前微波遥感领域对众多地物进行散射分析的重要理论基础。经验模型多依赖于当时的地表条件和雷达参数, 缺乏普适性。而半经验模型在经验模型的基

础上进行优化和简化, 不需要过于复杂的模拟分析过程和实测参数。

常用机理模型如表 2 所示, 依据能量守恒定理, 以微分量的形式表示电磁波在散射介质内发生物理过程^[7]。在该理论中, 用矢量强度来描述电磁波在随机介质中的吸收、散射和传播, 在估算土壤水分过程中, 通常会将植物叶、茎以及土壤下垫面等假设为介质圆柱体, 进行散射矩阵简化建模^[8]。具体方法以积分方程模型(Integral Equation Model, IEM)、经验半经验模型为主, 这些基于电磁波传播理论的地表微波辐射模型比较复杂, 需要大量的参数。SAR 的后向散射系数表达 σ_{pq}^0 为:

$$\sigma_{pq}^0 = \frac{k^2}{2} |f_{pq}|^2 2e^{-4s^2k^2 \cos^2 \theta} \sum_{n=1}^{+\infty} \frac{(4s^2k^2 \cos^2 \theta)^n}{n!} W^n(2k \sin \theta, 0) + \frac{k^2}{2} \operatorname{Re}(f_{pq}^* F_{pq}) e^{-3s^2k^2 \cos^2 \theta} \sum_{n=1}^{+\infty} \frac{(4s^2k^2 \cos^2 \theta)^n}{n!} W^n(2k \sin \theta, 0) + \frac{k^2}{8} |f_{pq}|^2 2e^{-2s^2k^2 \cos^2 \theta} \sum_{n=1}^{+\infty} \frac{(s^2k^2 \cos^2 \theta)^n}{n!} W^n(2k \sin \theta, 0) \quad (1)$$

式中, W^n 为表面相关函数的幂次傅里叶变换。 Re 为表面反射率; *表示共轭; k 为波数; s 为土壤表面均方根高度; θ 为雷达入射角; f_{pq} 为基尔霍夫系数, F_{pq} 为补偿场系数; pq 表示极化状态。

由于 IEM 模型对不同粗糙条件下的地表微波散射的准确性存在差异, 研究人员对 IEM 模型进行了改进, 提出 AIEM 模型 (Advanced Integral Equation Model, AIEM), 改进主要体现在 AIEM 中引入了基于格林函数简化假设的 Kirchhoff 场系数和互补场系数的完整表达式, 以及利用过渡模型得到了连续菲涅尔反射系数^[9]。改进后的模型有更宽的粗糙度适用范围, 可以更精确地计算表面介电常数 (ε_r) 以及适应各种遥感配置。

经验模型是在地表粗糙度不变的假设下, 根据特定地点大量的实测数据建立后向散射系数与土壤水分之间的关系表达式。如 Dubois 模型^[10]在使用过程中, 由于其站点依赖性, 会出现模型普适性的问题, 同时也有部分研究发现, 模型中的模拟值和测量值之间的差异往往达到几分贝, 使得土壤参数无法使用。针对模型泛化能力差的问题, Baghdadi 等^[11]针对实测雷达信号和模拟雷达信号之间的不一致以及适用条件过于繁琐的问题, 提出在 Dubois 模型的基础上结合土壤实测数据建立一个新的经验后向散射模型。改进后的模型在 C 波段和 X 波段均显示出更好的性能, 且在 HH 和 VV 极化方式下的偏差和均方根误差均有所减小。Dubois 模型适用于 $1.5 \text{ GHz} \leq f \leq 11 \text{ GHz}$, $30^\circ \leq \theta \leq 65^\circ$, $0.3 \text{ cm} \leq k \leq 3.0 \text{ cm}$, $m_v \leq 0.35 \text{ cm}^3 \cdot \text{cm}^{-3}$ 和 $\text{NDVI} \leq 0.4$ 的地表, 其中 f 为频率, m_v 为土壤水分, 具体表达方式如下:

$$\sigma_{\text{HH}}^0 = 10^{-2.75} \left(\frac{\cos^{1.5} \theta}{\sin^5 \theta} \right) 10^{0.028 \varepsilon_r \tan \theta} (ks \sin \theta)^{1.4} \lambda^{0.7} \quad (2)$$

$$\sigma_{\text{VV}}^0 = 10^{-2.35} \left(\frac{\cos^3 \theta}{\sin^3 \theta} \right) 10^{0.046 \varepsilon_r \tan \theta} (ks \sin \theta)^{1.1} \lambda^{0.7} \quad (3)$$

式中, ε_r 为介电常数; λ 为波长; θ 为雷达入射角; s 为土壤表面均方根高度; k 为自由空间波数, 其计算方式为 $k=2\pi/\lambda$ 。

随着人工智能技术的普及, 人工神经网络、支持向量机、遗传算法、代价函数优化法等机器学习方法也越来越多地运用于土壤水分反演^[12]。人工神经网络是将微波特征波段或特征波段衍生的特征参

数作为输入数据, 土壤水分作为输出数据, 以输入输出样本数据训练网络, 通过神经网络算法建立预测模型实现土壤水分反演, 具有较好的非线性映射能力和络柔性, 但易产生过拟合。支持向量机也是一种常见的机器学习方法, 通过建立土壤水分与后向散射系数、归一化植被指数 (Normalized Difference Vegetation Index, NDVI) 等参数在高维空间的映射关系, 实现对土壤水分的反演。

在机器学习的训练中, 需要对模型的超参数进行设置, 参数设置得过大或者过小均可能影响到拟合曲线的收敛速度和拟合效果, 将遗传算法 (Genetic Algorithm, GA) 和学习算法进行融合, 可自适应地判断超参数最优解, 进一步优化和提升学习模型的精度。代价函数优化方法是通过迭代算法最小化代价函数以获取地表参数的最优估计值, 由于优化代价函数法是具有一定物理意义的正向模型和全局优化算法, 也能够同步估计多个未知量, 因此该方法具有较高的普适性和可靠性。

半经验模型是经验模型和理论模型的一个折中, 借助实测数据简化理论模型, 得到较少受实验地点局限的关系模型, 因该模型建立在一定的统计规律上, 又可以在一定程度上反映散射机制, 能够获得较好的精度。水云模型 (Water Cloud Model, WCM) 是应用最多的半经验模型, 该模型将植被层假定为一个各向同性的散射体, 把地表后向散射描述为植被直接散射与经过植被双程衰减的土壤散射之和。水云模型一般表示为:

$$\sigma_{\text{can}}^0(\theta) = \sigma_{\text{veg}}^0(\theta) + \tau^2(\theta) \sigma_{\text{soil}}^0(\theta) \quad (4)$$

$$\sigma_{\text{veg}}^0(\theta) = AVI \cos \theta [1 - \tau^2(\theta)] \quad (5)$$

$$\tau^2(\theta) = \exp(-2BVI \sec \theta) \quad (6)$$

式中, σ_{can}^0 为地表总后向散射系数; σ_{veg}^0 为植被层直接后向散射系数; σ_{soil}^0 为土壤直接后向散射系数; τ^2 为植被层的双程衰减因子; θ 为雷达入射角; VI 为冠层植被指数; A 和 B 分别为与植被类型有关的经验系数。

VI 的确定可以借助于植被冠层含水量 (Vegetation Water Content, VWC)、叶面积指数 LAI、株高 H 、归一化植被指数 NDVI、植被覆盖度 (Fractional

表 2 关于土壤水分反演模型主动微波雷达的介绍

Table 2 Comparative characteristics of active microwave radar in soil moisture inversion mode

类型	名称	适用性	缺点
Category	Name	Applicability	Disadvantages
机理模型 Theoretical model	IEM 模型	适用于小范围不同粗糙程度表面	模型理论模拟值与地表实测后向散射值之间存在不一致性,地表粗糙度的表达方式尚不完善
	AIEM 模型	可以更加真实地模拟出自然状态下的随机地表散射特征	补充散射分量,非相干功率计算不精确、忽略误差函数
	小扰动模型	适用于低频率入射、相关长度较小的较为光滑表面	未考虑体积散射的影响
	MIMICS 模型	适用于森林等高大植被	输入参数复杂,难以在相对矮小的农作物区应用
经验模型 Empirical model	Oh 模型	适用于裸露地表、稀疏至中等密度的地表植被覆盖条件,植被高度小于 10~15 cm	受到入射角、均方根高度和介电常数的限制,过分依赖地面观测的经验参数
	Dubois 模型	在特定的地表粗糙度状况、微波频率、入射角大于 30°以及土壤含水量小于 35%的范围内适用	Dubois 模型不适用于粗糙程度较大的情况
半经验模型 Semi-empirical model	Shi 模型	适用于裸露地表、稀疏至中等密度的地表植被覆盖条件	只适用于同极化方式的影像数据
	水云模型	植被覆盖区域土壤含水率、模型中的植被冠层参数可利用光学遥感中的植被指数估计	农田地表受翻耕、播种、收割等活动的影响会造成地表粗糙度的变化,其差异会影响反演精度。该模型忽略了植被和地表的交互散射项,对具有一定高度的植被不适用

vegetation cover, FVC) 等指标。为了更加准确地评估植被覆盖对于土壤水分的影响,很多研究对水云模型进行了改进, Li 和 Wang^[13]在传统水云模型中引入了合成孔径雷达 HV 极化后向散射系数、雷达植被指数 (Radar vegetation index, RVI) 以及归一化植被指数对水云模型进行校正,用于多种卫星数据估算农田表层土壤水分,且反演效果要优于传统模型。

以上方法在微波反演土壤水分研究中取得了重要的进展,但是土壤水分与后向散射系数之间的复杂关系,特别是消除植被、地表粗糙度等对雷达后向散射系数的干扰方面,还需要进一步地研究。

2.2 被动微波遥感反演

主动微波受土壤表面粗糙度和植被覆盖的影响,在下垫面复杂的山区适用性较差。而被动微波对土壤水分敏感性更高,受植被、地表粗糙度和云层的影响更小,运用其反演土壤水分被认为是当前

监测土壤含水量最有效的手段之一^[14]。对于基于被动微波土壤水分的反演方法,虽然回归方法在很多领域得到很好的应用,但是在反演土壤水分的过程中可能会出现离群数据、非线性、异方差和多重共线性等问题,会导致反演精度过低而不能满足研究需要。

针对以上问题,研究人员提出了很多改进方法,主要从两个方向进行改进,一个是从丰富数据源方面,如 Wang 等^[15]利用贝叶斯最大熵算法将 FY-3B 与多种辅助数据 (NDVI、地表温度、高程、坡度、坡向等) 整合到估算土壤水分的模型中;另一个是从优化反演方法方面:人工智能机器学习在对大数据集进行自动或半自动探索和分析方面有很大优势,具有在数据之间发现规律或者模拟的能力,给土壤水分的估算提供了很多思路。很多研究利用被动微波遥感数据结合辅助数据利用机器学习方法,如自回归神经网络算法、支持向量机、随机森林和反向传播神经网络等建立水

分和多种要素间的非线性关系^[16], 实现土壤水分的遥感反演。结果证明机器学习方法在捕获土壤水分的时间和空间变化方面具有独特的优势^[17]。

针对植被覆盖干扰的问题, 研究人员在数据集优选和算法改进方面进行了尝试。如在数据集的使用上, Ma 等^[18]证明 SMAP 在地表温度、植被光学深度 (Vegetation Optical Depth, VOD)、地表粗糙度和空间非均质性多种扰动因素作用下依旧有较好的精度; 对于浓密植被区域, 改进的 SMOS-INRA-CESBIO (SMOS-IC) 较 SMOS-L3 产品在反演精度上有较大的提升。其次在算法的改进上, Li 等^[19]提出了一种多通道反演算法, 将土壤类型和植被覆盖度作为优选特征来评估植被对土壤水分反演过程的动态变化, 该算法能够确保针对植被覆盖区域有更高的数据精准度来反演土壤水分。

被动微波遥感具有较高的时间分辨率, 重返周期在 1~3 d, 能较好地反映土壤水分随时间变化的趋势, 但缺点是空间分辨率较低 (25~50 km)。这样的空间分辨率适用于全球及大区域的土壤水分监测, 但不能满足小尺度或者小区域范围对高分辨率土壤水分监测的需求。在实际应用中, 地表蒸散发模型、陆面过程模型以及水分模型等需要 10 km 甚至更高分辨率的土壤水分作为驱动数据^[20], 因而土壤水分降尺度的相关研究成为当前被动微波反演土壤水分的关键技术和热点, 使实测数据与降尺度数据在空间分辨率上实现更好的匹配^[21]。

目前的降尺度方法归纳为基于地统计方法、基于数理统计方法、基于数据同化方法以及基于多源遥感数据融合方法四种 (表 3):

(1) 通过地统计插值的方法来表达土壤水分的空间分布变化模式和其他地表环境参数 (如海拔、地形、土壤属性、植被覆盖度等) 的空间分布变化模式之间存在的联系, 插值之后的数据较为平滑。一般的插值模型如线性插值、克里金插值、多项式插值法, 插值过程依赖调参, 被 SMAP 数据中心用于反演 SMAP (9 km×9 km) 产品^[22]。但目前该方法依赖大量实测数据, 同时在某一特定区域建立的地统计插值模型很难应用到其他区域^[23], 所以该方法在缺失实测数据的研究区域很难得到应用。

(2) 基于数理统计方法主要包括多元统计回归和机器学习方法。多元统计回归方法是通过建立低空间分辨率下土壤水分与其相关参量之间的回归关

系式, 之后将该关系式应用到高空间分辨率下, 从而获得高空间分辨率的土壤水分含量。Tian 等^[24]利用多元统计法建立 MODIS 地表温度、NDVI 与 SMOS 土壤水分产品之间的回归关系, 并成功降尺度至 10 km 和 1 km。该方法计算形式简单、适用性较强, 但缺点首先是没有考虑尺度效应, 不确定建立的回归关系式是否可以跨越不同尺度, 其次, 回归关系式的具体形式会随着时间和空间的变化而改变, 针对不同的情况需要重新建立关系式, 效率较低。近年来土壤水分数据降尺度研究越来越多使用了机器学习方法, 探究土壤水分与多种要素间复杂的非线性关系, 如人工神经网络、梯度增强决策树回归等^[25]。Srivastava 等^[26]利用人工神经网络、支持向量机、相关向量机三种机器学习方法将 MODIS 的地表温度和 SMOS 数据集成进行降尺度运算, 发现其在季节变换尺度下有较好的性能。

(3) 数据同化方法主要将观测数据信息融入数学模型中, 通过最小化模型预测值与观测数据之间的代价函数, 计算得出模型估算值^[27]。Pellenq 等^[28]等将低分辨率的遥感数据同化到土壤水分模型中, 利用流域尺度上的水热平衡方程, 结合降雨数据、地形和土壤深度信息等将低分辨率的土壤水分分解到高分辨率下, 实现降尺度的目标。该方法的缺点就是辅助数据若有缺失会导致模型功能受到限制。

(4) 基于多源遥感数据融合的降尺度方法主要是扩展了遥感数据源, 其优点是对站点观测数据的依赖较少^[29]。该方法应用于较大尺度的研究区域, 其普适性得到明显增强。多源数据融合分为主被动微波遥感融合和被动微波与光学遥感融合两种数据融合。基于主被动微波遥感结合的降尺度方法^[30]假定每一个像元的区域内的地表粗糙度不变, 这样可以利用多时相遥感数据消除其对微波信号反射过程的影响, 之后建立低分辨率被动微波的土壤水分数据与主动微波观测得到后向散射系数之间的模型。经过偏差校正处理之后, 将该模型应用到主动微波数据和对应的高空间分辨率尺度, 即完成降尺度过程。主被动微波结合可以降低主动微波对地表微结构参数敏感性带来的不确定性, 但是主被动微波结合要求两者散射计对于观测目标具有相同的过境时间和重访周期, 这个问题有待进一步解决。

基于被动微波与光学遥感结合的降尺度方法是通过建立被动微波土壤水分数据与可见光—近红外

波段以及热红外波段光谱之间的响应关系来实现降尺度的目标。三角特征空间函数模型是被动微波与光学遥感结合最常用的降尺度模型之一^[31]。该模型是在气象条件、太阳辐射以及地物类型差异较小的地表基础上，通过遥感方法利用地表温度和植被叶面积指数（或植被指数）的变化规律实现对土壤水分和蒸散通量结果的有效估算，并建立土壤水分与地表温度和植被指数之间的经验多项式函数，实现土壤水分降尺度的目的。后续研究又在此基础上加入了其他不同的遥感输入变量（地表反照率、被动微波亮温等）^[32]以增强模型的普适性并提高土壤水分降尺度的精度。蒸散率法是将微波数据与光学气象数据相结合，主要通过一阶泰勒展开式建立土壤水分与蒸散发效率之间的降尺度关系，蒸散效率为

地表真实蒸散量与潜在蒸散量的比值，蒸散效率与土壤水分之间存在如下物理关系^[33]。

$$E_{SE} = 1 - e^{-\frac{M_s}{M_{Sc}}} \quad (7)$$

式中， E_{SE} 为土壤的蒸散效率； s 为土壤水分， $M_{Sc} = M_{Sc0}(1 + \gamma/\gamma_{ah})$ ， γ 和 M_{Sc0} 是与土壤质地和大气温度、风速有关的参数， γ_{ah} 是在一定风速和粗糙度下地表的热力学粗糙度。

虽然很多学者利用该方法进行大规模的水文研究，成功将大尺度的遥感数据降尺度至 1~10 km，但是该方法会受到很多因素的影响，例如大气状况、风速、地表粗糙度等，在降尺度过程中，蒸散模型还需要输入风、土壤质地等信息，所以在地表环境复杂的区域，该方法的应用会受到限制。

表 3 被动微波降尺度方法对比特征

Table 3 Comparative characteristics of passive microwave downscaling methods

类型 Category	方法 Method	优点 Advantage	缺点 Disadvantages
地统计方法 Geostatistical method	地统计插值法	插值之后的数据较为平滑	该方法依赖大量实测数据，同时在某一特定区域建立的地统计插值模型很难应用到其他区域中
数理统计方法 Mathematical statistical method	多元统计回归方法	方法形式简单、可解释性强、适用性较强	未考虑尺度效应，不确定建立的回归关系式是否可以跨越不同尺度；回归关系式的具体形式会随着时间和空间的变化而改变，针对不同的情况需要重新建立关系式，效率较低
	机器学习方法	可以纳入更多的特征，表达与多种要素间复杂的非线性关系	黑箱机制使得方法的可解释性较差
数据同化方法 Data assimilation method	数据同化方法	融入多源遥感数据和先验知识，实现遥感反演的时间过程扩展，提高地表参数的反演精度	辅助数据若有缺失会导致模型的功能受到限制
多源数据融合方法 Multi-source data fusion method	主被动微波遥感融合 被动微波与光学遥感融合	可以降低主动微波对地表微结构参数敏感带来的不确定性 方法简单易行、运算时效性高、对不同的研究区环境均有较强的适用性	不同传感器具有观测时刻或重访周期不一致的问题 未考虑不同像元下垫面环境因素影响，同时光学遥感在云雨天气下存在数据缺失问题

2.3 主被动微波遥感结合反演

被动微波有着较高的时间分辨率、对土壤水分敏感的优点，但其空间分辨率低；而主动微波遥感的特点是时间分辨率低，对地表粗糙度和植被结构敏感，但其空间分辨率高。可见两者在反演土壤水分方面有着各自的优势和劣势，微波遥感融合方法

依托丰富的数据源、相对成熟的观测技术和理论基础，在提取土壤水分信息方面具有良好的潜力，两者的结合不但可以实现上一节提出的降尺度目标，同时也可以实现反演精度提升或者获取长时间序列数据来满足研究需求的目标。

主被动微波结合的土壤水分反演方法根据原理

大致也可分为机理模型、经验模型以及半经验模型三种。

基于机理模型的主被动微波遥感结合方法主要是将从主动微波遥感中获取的关于植被和地表粗糙度的信息作为被动微波模型中的参数，利用辐射传输模型反演土壤水分^[34]。该方法在获取植被信息时，需要冠层高度、几何形状等多种实测数据，对不同农作物没有良好的普适性，同时计算得到的地表粗糙度与地表实测后向散射值之间存在不一致性，地表粗糙度的表达方式尚不完善，因此对算法的推广有一定限制。

基于经验模型的主被动微波遥感结合方法主要是利用数学优化理论构建核心算法，融合主动微波的雷达后向散射数据和被动微波的亮温数据，来反演土壤水分。例如利用贝叶斯融合方法将雷达后向散射数据与亮温数据进行融合，通过反复调整模型参数，使代价函数取得最优解^[35]，或者使用累积分布频率（Cumulative Distribution Function, CDF）匹配算法对多个数据集进行重新排序和组合，修正其中的线性偏差，以获得精确度更高的土壤水分数据^[36]。欧洲航天局气候变化倡议开发的全球日数据集（European Space Agency Climate Change Initiative,

ESA-CCI）就是运用该方法将多种主动被动微波传感器数据融合而成的。其中主动、被动微波土壤水分产品分别采用了基于变化检测的土壤水分反演方法^[37]和陆表参数反演模型（Land Parameters Retrieval Model, LPRM）。多位学者运用全球土壤水分观测系统以及三重配置分析或者改进三重配置（Extend Triple Collocation, ETC）方法证明了该方法反演精度较高，结果可靠^[38]。

由于重访时间、季节性的冰期或射频干扰（Radio Frequency Interference, RFI）等因素的存在，主被动微波遥感结合的反演方法常常会产生数据缺失的问题，对数据的时空连续性影响很大。针对缺失数据，许多研究采用插值方法进行填补。常用的插值方法分为基于时间的插值方法、基于空间的插值方法以及基于统计学的插值方法三种类型（表4），其中基于时间的插值方法主要是利用所插值的数据与生物过程时间动态之间的关系^[39]，基于空间的插值方法则是利用存在数据缺失的像元周边的（不存在数据异常的）像元信息进行插值^[40]。而基于统计学的插值方法以近期热点机器学习方法为主，主要包括支持向量机（Support Vector Machine, SVM）、决策树（Decision Tree, DT）、人工神经网络等方法。

表4 数据缺失插值方法对比特征

Table 4 Comparative characteristics of data missing interpolation methods

类型	方法	适用性	缺点
Category	Method	Applicability	Disadvantages
基于时间的插值方法	线性插值	当原始数据序列具有较大的高质量数据比例（比如大于85%）	在数据外围易产生异常突变的值
Time-based interpolation method	样条插值	适用于属性值在短距离内变化不大的区域范围	能保证各小段曲线在连接点的连续性，却无法保证整条曲线的光滑性
	时间序列谐波法	适用于年际波动较小的生态系统	数据缺失持续的时间长，不能成功识别周期及振荡，导致得到的结果缺乏可信度
基于空间的插值方法	地统计学插值	适用于样本数据存在随机性和结构性特征的场景	在辅助数据高度稀疏或聚集的区域结果具有不确定性，同时还需要评价空间自相关效应
Space-based interpolation method	反距离加权插值	观察点数据集均匀分布且足够密集以反映局部差异	权重函数存在细微差别对结果有较大的波动，同时易受观测点数据集的影响，可能出现孤立的分布模式
基于统计学的插值方法	机器学习方法	训练数据分布均匀，同时各变量与因变量之间存在非线性关系	机器学习的预测精度依赖于训练样本，当训练样本不包含区域内的特征时，可能降低部分区域的预测精度
Statistics-based interpolation method			

基于半经验模型的主被动微波遥感结合方法主要是利用基于多种实测数据对理论模型进行局部简化, Lee 和 Anagnostou^[41]利用菲涅尔模型和简单的植被模型模拟被动微波辐射, 利用几何光学模型模拟主动微波散射, 植被的影响采用半经验模型水云模型来计算模拟, 基于这些前向模型建立起模拟值与影像数据之间的函数关系, 模型的参数需要利用站点的实测土壤水分以及其他观测数据进行标定。该方法未能将主动数据空间分辨率的优点发挥出来, 同时模型需要大量的实测数据进行参数定标, 限制了算法在缺乏实测数据地区的推广。

3 展 望

土壤水分含量影响地—气系统中的能量交换, 是水文模型、气候模型、生态模型和陆面过程等模型的关键变量, 直接影响作物生长发育, 是长势监测、产量预报、土壤墒情等农业应用的重要因子。而遥感技术具有观测范围广、周期性、长时间序列的优势, 使得在土壤水分反演过程中充分利用, 微波遥感的发展, 波段范围的扩大, 反演算法的不断改进, 均会使反演精度得到提升, 但是离研究需求和尺度需求还存在一定的差距, 主要是受到大尺度下气候条件、土壤现状、空间异质性等原因的影响。其次是近些年来, 基于 GNSS 陆面遥感的研究发展较快, L 波段的微波信号稳定, 能精确估算陆面、海洋等相关信息, 可以作为未来遥感领域的重要方向。

3.1 通过改进反演过程提升反演精度

现阶段在小尺度区域下, 土壤水分反演精度可以满足部分研究的需求, 但是在全球尺度上由于气候、土壤、空间异质性等原因, 出现数据缺失、精度不高等现象。虽然很多研究利用数据协同使得反演水分精度有部分提升, 但是依然难以适用于其他不同区域。例如 Hagan 等^[42]利用 ESA-CCI 数据以及多种再分析数据计算中国不同气候区的土壤水分含量以及估算误差, 研究发现多种数据下的青藏高原地区因其独特地势和气候敏感性原因, 估算误差较大, 所以急需改善全球尺度下的土壤水分反演精度以及解决空间异质性的相关问题。

就目前已经公布的全球土壤水分产品来看, 空间分辨率较为粗糙, 很难应用于区域的精细化研究,

且还存在时间序列不连续的问题。解决这些问题主要是对反演过程的初期、中期阶段进行改进:

首先在反演过程初期, 借助多种观测方式(多极化、多角度、多波段)以及多时相重复观测作为模型输入特征, 可以很大程度降低土壤水分反演的不确定性, 提升预测能力; 在一定入射角度的观测条件下, 水平极化和垂直极化亮温的菲涅耳反射信号对介电常数变化的敏感性具有较大的差异, VV 极化对于植被和土壤水分具有敏感性, 而 VH 极化对于植被变化更为敏感, 多种极化组合方式可以修正模型中原有的后向散射系数; 而不同的入射角度和入射波长代表目标物吸收不同能量和散射界面的大小, 对反演过程有不同程度的影响, 多次进行试验便于找到最优方式进行水分含量估算。

同时反演过程在很大程度上受到土壤类型、植被覆盖等众多因素的影响, 且很难反映出土壤水分的垂向变化过程, 通过运用数据同化方法对多源数据进行融合, 在陆面水文模型中添加地表热通量、土壤蒸散发、降雨等参数化过程协同模拟计算, 将不同来源的观测数据融合到陆面水文模型中, 自动更新系统的状态变量, 提高关键性参数的准确性, 可以进一步降低不确定性增加预测精度。

其次在反演过程中期, 可以引入新的计算方法以及在原有的模型上进行改进, “大气-植被-地表”多层介质结构的穿透能力存在差异, 一些传统模型中没有对大气参数进行校准, 因而提出一些新的大气参数参与到模型的建立中, 减少风速、空气温度、湿度、气溶胶等因素对能量传输过程的影响。也可采取机器学习等方法(人工神经网络、遗传算法、支持向量机等)很好地建立大数据样本和输出之间的关系, 在提高精度的同时还可以解决模型过拟合的问题以及改进算法收敛速度较慢、训练过程中误差不稳定等现象, 也可以利用特有参数对植被覆盖、地表粗糙度、土壤类型等现实情况对反演模型进行简化。

3.2 GNSS-R 陆面遥感有待挖潜

基于 GNSS 反射信号的遥感技术(Global Navigation Satellite System-Reflection, GNSS-R)探测土壤水分是近年来一个新兴的研究方向。全球导航卫星系统 GNSS 是为提供导航定位服务而发展的一类卫星系列。全球 4 大导航系统, 即美国的 GPS、中国的北

斗、俄罗斯的 GLONASS 和欧盟的 Galileo 卫星, 目前已有 100 多颗卫星在轨运行。GNSS-R 利用导航卫星提供的长期稳定、高时空分辨率的 L 波段微波信号, 它兼具主动雷达与被动辐射计的优点^[43]。在海面遥感(海面风场和海面高度)、陆面遥感(植被状态、土壤水分、积雪深度)等应用领域均有很好的发挥^[44]。

而中国 GNSS-R 陆面遥感相关研究起步较晚, 清华大学、北京大学团队在 2015—2016 年开展不同地域和气候条件下的陆表及大气参数反演方法研究^[45]。中国自主研发的北斗系统在 2020 年完成全部建设, 系统将由 35 颗卫星组成, 包括 5 颗静止轨道(Geostationary Orbit, GEO)卫星、27 颗中地球轨道(Middle Earth Orbit, MEO)卫星和 3 颗倾斜同步轨道(Inclined GeoSynchronous Orbit, IGSO)卫星, 该系统能够提供与 GPS 系统类似的 L 波段微波信号, 且实现全球覆盖。因此北斗系统具有较 GPS 系统更丰富的卫星轨道设计, 所以充分发掘北斗导航系统的遥感应用潜力, 大力发展其在气象、地震、海洋、陆面应用优势, 是未来中国 GNSS 遥感领域发展一个重要方向。

参考文献 (References)

- [1] Yee K E. Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media[J]. IEEE Transactions on Antennas and Propagation, 1966, 14 (3): 302—307.
- [2] Zeng J Y, Li Z, Chen Q, et al. Evaluation of remotely sensed and reanalysis soil moisture products over the Tibetan Plateau using in situ observations[J]. Remote Sensing of Environment, 2015, 163: 91—110.
- [3] Shukla J, Mintz Y. Influence of land-surface evapotranspiration on the earth's climate[J]. Science, 1982, 215 (4539): 1498—1501.
- [4] Cheng L, Jiao X, Di H Y, et al. Spatio-temporal distribution of soil moisture on slopes relative to land preparation measure[J]. Acta Pedologica Sinica, 2021, 58 (6): 1423—1435. [程谅, 焦雄, 邸涵悦, 等. 不同整地措施坡面土壤水分时空分布特征[J]. 土壤学报, 2021, 58 (6): 1423—1435.]
- [5] Yan S H, Gong J Y, Zhang X X, et al. Ground based GNSS-R observations for soil moisture[J]. Chinese Journal of Geophysics, 2011, 54 (11): 2735—2744. [严颂华, 龚健雅, 张训械, 等. GNSS-R 测量地表土壤湿度的地基实验[J]. 地球物理学报, 2011, 54 (11): 2735—2744.]
- [6] Zhao S H, Qin Q M, Shen X Y, et al. Review of microwave remote sensing on soil moisture monitoring[J]. Journal of Microwaves, 2010, 26 (2): 90—96. [赵少华, 秦其明, 沈心一, 等. 微波遥感技术监测土壤湿度的研究[J]. 微波学报, 2010, 26 (2): 90—96.]
- [7] Kweon S K, Oh Y. A modified water-cloud model with leaf angle parameters for microwave backscattering from agricultural fields[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53 (5): 2802—2809.
- [8] Zhao S H, Zhang C M, Xiong Y J, et al. Soil moisture mapping using two scenes SAR imagery without knowing information on surface parameters[J]. Journal of the Indian Society of Remote Sensing, 2016, 44 (4): 651—656.
- [9] Chen K S, Wu T D, Tsang L, et al. Emission of rough surfaces calculated by the integral equation method with comparison to three-dimensional moment method simulations[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41 (1): 90—101.
- [10] Dubois P C, van Zyl J, Engman T. Measuring soil moisture with imaging radars[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(4): 915—926.
- [11] Baghdadi N, Choker M, Zribi M, et al. A new empirical model for radar scattering from bare soil surfaces[J]. Remote Sensing, 2016, 8 (11): 920.
- [12] Senyurek V, Lei F N, Boyd D, et al. Machine learning-based CYGNSS soil moisture estimates over ISMN sites in CONUS[J]. Remote Sensing, 2020, 12 (7): 1168.
- [13] Li J H, Wang S S. Using SAR-derived vegetation descriptors in a water cloud model to improve soil moisture retrieval[J]. Remote Sensing, 2018, 10 (9): 1370.
- [14] Mladenova I E, Jackson T J, Njoku E, et al. Remote monitoring of soil moisture using passive microwave-based techniques—Theoretical basis and overview of selected algorithms for AMSR-E[J]. Remote Sensing of Environment, 2014, 144: 197—213.
- [15] Wang S, Wang Y X, Zhang C, et al. Research on fusing multisatellite soil moisture data based on Bayesian model averaging[J]. Advances in Meteorology, 2018, 2018: 9310838.
- [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] Ford T W, Quiring S M, Zhao C, et al. Triple collocation evaluation of in situ soil moisture observations from 1200+ stations as part of the US national soil moisture network[J]. Journal of Hydrometeorology, 2020, 21 (11): 2537—2549.

- [18] Ma H L, Zeng J Y, Chen N C, et al. Satellite surface soil moisture from SMAP, SMOS, AMSR2 and ESA CCI: A comprehensive assessment using global ground-based observations[J]. *Remote Sensing of Environment*, 2019, 231: 111215.
- [19] Li X J, Wigneron J P, Fan L, et al. A new SMAP soil moisture and vegetation optical depth product (SMAP-IB): Algorithm, assessment and inter-comparison[J]. *Remote Sensing of Environment*, 2022, 271: 112921.
- [20] Crow W T, Wood E F, Dubayah R. Potential for downscaling soil moisture maps derived from spaceborne imaging radar data[J]. *Journal of Geophysical Research: Atmospheres*, 2000, 105 (D2): 2203—2212.
- [21] Brocca L, Melone F, Moramarco T, et al. Spatial-temporal variability of soil moisture and its estimation across scales[J]. *Water Resources Research*, 2010, 46 (2): W02516.
- [22] Das N N, Entekhabi D, Njoku E G. An algorithm for merging SMAP radiometer and radar data for high-resolution soil-moisture retrieval[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49 (5): 1504—1512.
- [23] Peng J, Loew A, Merlin O, et al. A review of spatial downscaling of satellite remotely sensed soil moisture[J]. *Reviews of Geophysics*, 2017, 55 (2): 341—366.
- [24] Tian J, Deng X Z, Su H B. Intercomparison of two trapezoid-based soil moisture downscaling methods using three scaling factors[J]. *International Journal of Digital Earth*, 2019, 12 (4): 485—499.
- [25] Wei Z S, Meng Y Z, Zhang W, et al. Downscaling SMAP soil moisture estimation with gradient boosting decision tree regression over the Tibetan Plateau[J]. *Remote Sensing of Environment*, 2019, 225: 30—44.
- [26] Srivastava P K, Han D W, Ramirez M R, et al. Machine learning techniques for downscaling SMOS satellite soil moisture using MODIS land surface temperature for hydrological application[J]. *Water Resources Management*, 2013, 27 (8): 3127—3144.
- [27] Man J, Zhang J J, Zheng Q, et al. Data assimilation for soil hydraulic parameter estimation: Progress and perspectives[J]. *Acta Pedologica Sinica*, 2023, 60 (6): 1543—1554. [满俊, 张江江, 郑强, 等. 基于数据同化的土壤水力参数反演方法: 研究进展与展望 [J]. *土壤学报*, 2023, 60 (6): 1543—1554.]
- [28] Pellenq J, Kalma J, Boulet G, et al. A disaggregation scheme for soil moisture based on topography and soil depth[J]. *Journal of Hydrology*, 2003, 276 (1/2/3/4): 112—127.
- [29] Song P L. Improved surface soil moisture estimation methods and their applications based on AMSR radiometers[D]. Hangzhou: Zhejiang University, 2019. [宋沛林. 基于 AMSR 被动微波辐射计的地表土壤含水量估算方法改进及应用研究[D]. 杭州: 浙江大学, 2019.]
- [30] Leroux D J, Das N N, Entekhabi D, et al. Active-passive soil moisture retrievals during the SMAP validation experiment 2012[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13 (4): 475—479.
- [31] Zhang Z M, He G J, Wang M M, et al. Towards an operational method for land surface temperature retrieval from Landsat 8 data[J]. *Remote Sensing Letters*, 2016, 7 (3): 279—288.
- [32] Piles M, Sánchez N, Vall-llossera M, et al. A downscaling approach for SMOS land observations: Evaluation of high-resolution soil moisture maps over the Iberian peninsula[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7 (9): 3845—3857.
- [33] Wang K C, Li Z Q, Cribb M. Estimation of evaporative fraction from a combination of day and night land surface temperatures and NDVI: A new method to determine the Priestley-Taylor parameter[J]. *Remote Sensing of Environment*, 2006, 102 (3/4): 293—305.
- [34] O'neill P E, Chauhan N S, Jackson T J. Use of active and passive microwave remote sensing for soil moisture estimation through corn[J]. *International Journal of Remote Sensing*, 1996, 17 (10): 1851—1865.
- [35] Lee C S, Dong Park J, Shin J, et al. Improvement of AMSR2 soil moisture products over south Korea[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10 (9): 3839—3849.
- [36] Zhan X W, Houser P R, Walker J P, et al. A method for retrieving high-resolution surface soil moisture from hydros L-band radiometer and Radar observations[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44 (6): 1534—1544.
- [37] Wagner W, Lemoine G, Rott H. A method for estimating soil moisture from ERS scatterometer and soil data[J]. *Remote Sensing of Environment*, 1999, 70 (2): 191—207.
- [38] Dorigo W A, Gruber A, de Jeu R A M, et al. Evaluation of the ESA CCI soil moisture product using ground-based observations[J]. *Remote Sensing of Environment*, 2015, 162: 380—395.
- [39] Julien Y, Sobrino J A. Comparison of cloud-reconstruction methods for time series of composite NDVI data[J]. *Remote Sensing of Environment*, 2010, 114 (3): 618—625.
- [40] Li H T, Shao Z D. Review of spatial interpolation analysis algorithm[J]. *Computer Systems & Applications*, 2019,

- 28 (7): 1—8. [李海涛, 邵泽东. 空间插值分析算法综述[J]. 计算机系统应用, 2019, 28 (7): 1—8.]
- [41] Lee K H, Anagnostou E N. A combined passive/active microwave remote sensing approach for surface variable retrieval using Tropical Rainfall Measuring Mission observations[J]. Remote Sensing of Environment, 2004, 92 (1): 112—125.
- [42] Hagan D F T, Parinussa R M, Wang G J, et al. An evaluation of soil moisture anomalies from global model-based datasets over the People's republic of China[J]. Water, 2019, 12 (1): 117.
- [43] Li H, Xia Q, Yin C, et al. The Current status of research on GNSS-R remote sensing technology in China and future development[J]. Journal of Radars, 2013, 2 (4): 389—399. [李黄, 夏青, 尹聪, 等. 我国 GNSS-R 遥感技术的研究现状与未来发展趋势[J]. 雷达学报, 2013, 2 (4): 389—399.]
- [44] Garrison J L, Cardellach E, Gleason S, et al. Foreword to special issue on reflectometry using global navigation satellite systems and other signals of opportunity (GNSS R) [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7 (5): 1412—1415.
- [45] Wan W, Chen X W, Peng X F, et al. Overview and outlook of GNSS remote sensing technology and applications[J]. Journal of Remote Sensing, 2016, 20 (5): 858—874. [万玮, 陈秀万, 彭学峰, 等. GNSS 遥感研究与应用进展和展望[J]. 遥感学报, 2016, 20 (5): 858—874.]

(责任编辑: 檀满枝)