doi:10.6041/j.issn.1000-1298.2025.06.042

基于协同克里金插值的土壤耕作层含水率反演方法

郭　交[1,2]　朱　哲[1]　项诗雨[1]　邝晓飞[1]　尉鹏亮[1,2]

(1.西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;
2.陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100)

摘要: 土壤耕作层是作物生长发育的基础,准确监测土壤耕作层含水率并对作物进行精准灌溉能提高作物产量和水资源利用率。为实现高效监测土壤耕作层含水率,提出一种基于协同克里金插值的土壤耕作层含水率反演方法。首先以能够获取土壤表层信息的 Sentinel - 1 卫星数据为本文数据源,与具有可靠运算能力的 XGBoost (Extreme gradient boosting)模型结合可以高效反演土壤表层含水率;将其大范围土壤含水率反演结果作为协变量,把 115 个实测土壤耕作层含水率作为主变量,利用土壤表层与耕作层变量间的协同关系,采用协同克里金方法插值得到土壤耕作层含水率;协同克里金法可以很好地利用土壤表层与耕作层变量间的协同关系提升插值精度,并且在一定程度上可解决土壤耕作层含水率实测数据量不足的问题。将土壤耕作层含水率克里金插值和利用表层与耕作层含水率线性拟合进行对比,结果表明,采用协同克里金插值反演土壤耕作层含水率能够大幅提高预测准确性,决定系数 R^2 分别提高 0.25 和 0.20,均方根误差(RMSE)分别降低 0.029、0.014 cm^3/cm^3,平均绝对误差(MAE)分别降低 0.028、0.015 cm^3/cm^3,精度显著提高。

关键词: 土壤耕作层; 土壤含水率; 协同克里金; 遥感反演; 极端梯度提升

中图分类号: S127　　**文献标识码:** A　　**文章编号:** 1000-1298(2025)06-0457-11　　**OSID:**

Inversion of Soil Tillage Layer Moisture Content Based on Co-Kriging Interpolation

GUO Jiao[1,2]　ZHU Zhe[1]　XIANG Shiyu[1]　KUANG Xiaofei[1]　WEI Pengliang[1,2]

(1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Shaanxi Key Laboratory of Agriculture Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: The soil tillage layer is the foundation of crop growth and development. Accurately monitoring the moisture content of the soil tillage layer and providing precise irrigation to crops can improve crop yield and water resource utilization efficiency. To achieve efficient monitoring of soil tillage layer moisture content, a soil tillage layer moisture content inversion method based on collaborative Kriging interpolation was proposed. Firstly, Sentinel - 1 satellite data, which can obtain soil surface information, was used as the data source. Combined with the reliable XGBoost (extreme gradient boosting) model, it can efficiently invert soil surface moisture content. Using the large-scale soil moisture inversion results as covariates and 115 measured soil tillage layer moisture contents as main variables, the synergistic relationship between soil surface and tillage layer variables was utilized to interpolate the soil tillage layer moisture content using the collaborative Kriging method. The collaborative Kriging method can effectively utilize the synergistic relationship between soil surface and tillage layer variables to improve interpolation accuracy, and to some extent solve the problem of insufficient measured data on soil tillage layer moisture content. Comparing the Kriging interpolation of soil tillage layer moisture content with the linear fitting of surface and tillage layer moisture content, the results showed that using collaborative Kriging interpolation to invert soil tillage layer moisture content can significantly improve prediction accuracy. The coefficient of determination R^2 was increased by 0.25 and 0.20, the root mean square error (RMSE) was decreased by 0.029 cm^3/cm^3 and 0.014 cm^3/cm^3, and the average absolute error (MAE) was decreased by 0.028 cm^3/cm^3 and 0.015 cm^3/cm^3, respectively. The accuracy was significantly improved.

Key words: soil tillage layer; soil moisture content; co-Kriging; remote sensing inversion; extreme gradient boosting

收稿日期: 2024 - 12 - 18　修回日期: 2025 - 02 - 11

基金项目: 陕西省重点研发计划项目(2024NC - ZDCYL - 05 - 02)

作者简介: 郭交(1984—),男,教授,博士生导师,主要从事农业遥感和精准农业研究,E-mail: jiao.g@163.com

0 引言

土壤表层与耕作层是受耕作、灌溉、施肥等农业活动影响最直接的土层,土壤表层深度通常只有几厘米,而耕作层厚度一般为 15 ~ 20 cm[1]。土壤耕作层是农作物赖以生存的基础[2],其含水率受农事活动影响变化显著,目前常用的漫灌方式不但浪费水资源,也会破坏生态环境系统天然平衡状态[3],而针对土壤耕作层精准灌溉,不仅可降低土壤表层含水率,加大根系吸水深度,还有助于提高作物产量和水分利用率[4],对农事活动具有重要意义。

目前土壤耕作层含水率监测方法主要包括:①数据同化法,如 SMAP(Soil moisture active passive) L4 产品土壤根系层含水率估算[5]。②机器学习方法,利用土壤属性或遥感参数反演耕作层含水率[6],如徐驰等[7]将高光谱反演的土壤表层含水率结合实测土壤耕作层含水率,采用协同克里金法估计土壤耕作层含水率。③指数滤波法,通过建立水量平衡模型推导求得土壤含水率[8],如田静[9]使用指数滤波法估算深层土壤含水率。3 类方法中,数据同化法由于模型本身和观测带来的误差及不确定性,并不是常用的最优选择;指数滤波法依赖于大量观测数据难以保证监测时效性与精准性,无法准确获取关键参数 T 值,极大地限制了方法的应用[9]。机器学习估算土壤深层含水率比浅层土壤复杂,高光谱遥感监测土壤含水率可使用的可见光-近红外、热红外波段对土壤穿透深度有限,只能监测土壤表层几微米土壤含水率[10],而微波遥感则能精准探测土壤表层信息。并且高光谱遥感受限于天气、环境等因素不具备微波遥感全天候全天时、范围广精度高等优点,观测数据的稀缺性以及卫星遥感难以穿透到深层土壤都给土壤耕作层含水率监测带来了困难。但卫星微波遥感结合地理统计学方法监测土壤耕作层含水率少有研究。

人工神经网络、支持向量机等结合遥感指数构建多特征变量土壤含水率反演模型已成功应用于不同地区土壤含水率反演[11-12]。极端梯度提升[12]能够发现数据之间有意义的关联,依靠多次迭代学习能够有效提升预测效果;而卫星微波遥感可以大面积实时动态地监测土壤含水率,Sentinel - 1 卫星搭载的 C 波段合成孔径雷达可以很好地反映土壤表层信息,其结合机器学习方法可以高效反演土壤表层含水率。克里金插值方法可以在考虑空间变异的基础上,采用空间插值技术将有限的实测数据绘制尽可能真实的田间土壤含水率空间分布图[13]。而协同克里金法可以利用土壤性质间协同效应,将单一变量或多变量作为辅助变量从而提高估值精度[14]。因此,基于卫星微波遥感监测土壤表层含水率高时效性、高准确性等优点和土壤表层与耕作层含水率之间存在的统计量及物理意义上的联系[7-8],可以将大范围土壤表层含水率作为辅助数据,采用协同克里金插值方法估算大范围土壤耕作层含水率。避免了传统方法的费时费力且有效提升监测精度,应用更广泛。

研究区位于山东省烟台市牟平区姜格庄镇,本文利用 Sentinel - 1 卫星遥感反演得到研究区大范围土壤表层含水率;将土壤表层含水率反演结果作为协变量,部分土壤耕作层含水率实测数据作为主变量,采用协同克里金插值方法反演土壤耕作层含水率。以期为土壤耕作层含水率监测提供技术依据。

1 数据与方法

1.1 研究区概况

研究区(图 1a)位于山东省烟台市牟平区姜格庄镇东北部(121°47′ ~ 121°48′E,37°21′ ~ 37°26′N,海拔 0 ~ 40 m),属于典型暖温带大陆性季风气候。其中试验地面积为 6.6 km^2,如图 1b 所示。研究区土壤类型以棕壤土为主,土壤容重为 1.56 g/cm^3,年平均日照时数为 2 612 h,无霜期为 180 d,年平均气温为 12.2℃,年平均降雨量约为 763 mm,主要集中在 7—9 月,平均蒸发量 1 675.80 mm。研究区域内大部分农田为裸地,少部分农田种植冬小麦,数据采集时冬小麦处于越冬期。采样期间全天气温为 5 ~ 10℃,无风,采样时集中在 10:00—16:00,避开早晨空气湿度较大时间与傍晚降温时间,尽可能减少温度对土壤含水率的影响。根据农田实际分布范围,将研究区划分为 a、b 两部分,独立同时开展研究。

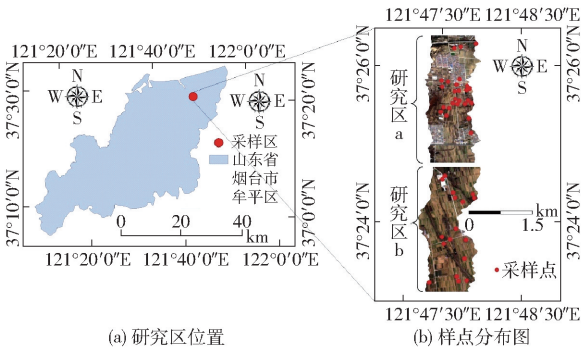

(a) 研究区位置 (b) 样点分布图

图 1 研究区位置与样点分布图

Fig. 1 Location of research area and sample distribution map

1.2 土壤样本采集与处理

于 2023 年 12 月 6—9 日进行地面数据采集,采样时间与遥感影像获取时间同步。采样点分布如

图 1b 所示，每个采样点至少采集 1 个，至多采集 3 个土壤含水率数据点。采集过程中，通过厘米级定位的双频 GPS（Global positioning system）接收机进行土壤含水率数据点定位，记录经纬度坐标等地面参数，确保数据准确性和可追溯性。采样时在土质或地形差异较小的农田分散采样，在因农事活动或其他因素导致的土质差异较大的农田采样点相对密集，整体采样点覆盖所有类型农田以确保样本代表性，同时确保采样点数量能满足模型训练。在采样点以半径 2 m 采用五点采样法进行采样，在每个采样点使用 TR－6D 型土壤含水率测量仪采集土壤表层含水率，采用剖面采样法采集 15～20 cm 土壤含水率，共得到 115 个样点土壤含水率。

1.3　遥感影像获取与特征参数提取

Sentinel－1 与 Sentinel－2 均隶属于欧洲航天局的 Sentinel 任务。Sentinel－1 卫星搭载 C 波段合成孔径雷达，波长为 0～5 cm，已有研究将其用来反演土壤表层含水率[15]，本文将其作为土壤表层含水率反演数据源。Sentinel－2 为光学遥感卫星，安装具有 13 个通道的多光谱成像仪。对 Sentinel－2 光学影像进行大气校正和重采样后，计算植被指数为土壤含水率反演提供数据源。选取 2023 年 12 月 5 日 Sentinel－1 的 GRDH 和 SLC 影像和 12 月 9 日的 Sentinel－2 影像，在 SNAP 软件中进行预处理，Sentinel－1 的 GRDH 雷达数据预处理主要有辐射定标，地形辐射校正、采用 Refined Lee 算法进行滤波[16]和地形校正等。对于 SLC 格式数据，预处理步骤包括辐射校正、拼接裁剪、极化分解、滤波去噪和地形校正。SLC 格式数据利用 $H/A/\alpha$ 分解，可以得到特征参数 H、A 和 α[17]。

1.3.1　特征参数提取

主动微波遥感反演土壤含水率主要依赖于对后向散射系数提供的信息进行精确推导。对于利用 C 波段进行土壤表层含水率反演，从预处理完成的 Sentinel－1 数据中提取特征参数，包括对应位置入射角 θ（即 LIA）、后向散射系数 σ^0_{VV}、σ^0_{VH} 和海拔（DEM）。文献[18]指出 $\cos\theta$ 和 $\sin\theta$ 与土壤含水率存在关联且两者与土壤含水率的影响关系不同，$\sigma^0_{VH}/\sigma^0_{VV}$在雷达入射角恒定条件下对土壤含水率有显著影响[19]，所以在特征选择中加入 $\cos\theta$、$\sin\theta$ 和 $\sigma^0_{VH}/\sigma^0_{VV}$。为了更全面描述土壤含水率特征，在特征参数中还加入 $\sigma^0_{VH}+\sigma^0_{VV}$、$\sigma^0_{VH}-\sigma^0_{VV}$、$\sigma^0_{VH}\times\sigma^0_{VV}$。另外，对 Sentine1－1 的 SLC 格式数据采用 $H/A/\alpha$ 分解，可得分别表示目标散射机理和目标散射极化程度的极化熵 H 和平均散射角 α，以及反熵 A。从 Sentinel－1 数据中提取出共计 13 个与土壤含水率紧密相关的特征参数。

由于研究区存在植被生长且地表环境存在一定的差异性，地表植被对土壤含水率存在影响，从 Sentinel－2 多波段光学数据中选取对土壤含水率有显著作用的 6 个植被指数参与建模[20]，分别为水分胁迫指数（MSI）、归一化差异植被指数（NDVI）、比值植被指数（RVI）、归一化差异水分指数（NDWI）、调整型土壤调节植被指数（MSAVI）和差值植被指数（DVI）。

1.3.2　全子集筛选

全子集回归是一种从候选预测变量中选择合适的变量子集以构建回归模型的统计方法，通过考虑所有可能的组合来寻找最佳模型。在回归分析中若有 K 个自变量作为候选预测变量，将因变量 Y 与其中任意 $M(M=1,2,\cdots,K)$ 个自变量拟合，构建回归方程，选出调整后决定系数 R^2_{adj}最大的 K 个模型；从 K 个模型中，依据赤池信息准则（Akaike information criterion，AIC）、R^2_{adj} 和贝叶斯信息准则（Bayesian information criterion，BIC）综合评价指标，选出最优模型[21]。

1.4　机器学习模型构建

极端梯度提升模型（XGBoost）以梯度下降树（Gradient boosting decision tree，GBDT）为基础，为损失函数进行了二阶泰勒计算得到的模型。相比于 GBDT，XGBoost 在优化目标函数提升预测精度的同时通过并行学习提高了计算速率[22]。XGBoost 模型使用训练集构建一棵初始树进行模型训练，得到模型预测值与实际值残差；每次迭代过程中都增加一棵树来拟合模型上次预测残差，直至模型学习进程被终止，由此形成由众多树模型集成的迭代残差树集合[22]。

在 Boosting 算法基础上，加入剪枝，使用列采样使模型过于复杂，XGBoost 模型还利用中央处理器多线程计算能力，加入正则化项抑制过拟合。Boosting 分类器关键点在于每一轮迭代树基础模型要能够针对现有集成的不足进行补偿。因此找到最大化降低的目标函数f_i 成为了关键，构建目标函数为

$$Obj^{(t)}=\sum_{i=1}^{n} l(y_i,\hat{y}_i^{(t)})+\sum_{i=1}^{t}\Omega(f_i)=\sum_{i=1}^{n} l[(y_i,\hat{y}_i^{(t-1)})+f_t(\boldsymbol{x}_{ii})]+\Omega(f_t)+c \quad (1)$$

式中　l——目标函数损失函数

y_i——实测值　　$\hat{y}_i^{(t)}$——预测值

$\boldsymbol{x}_{ii}$——每个数据点特征向量

$f_t(\boldsymbol{x}_{ii})$——第 t 个预测模型

$\Omega(f_t)$——正则项

c——常数

对于损失函数,可利用泰勒展开式对其进行近似估算。在此过程中,通过去除与当前迭代无关的常数项,可以进一步简化目标函数,即

$$Obj^{(t)} \cong \sum_{i=1}^{n} \left(g_i f_t(\boldsymbol{x}_{ii}) + \frac{1}{2} h_i f_t^2(\boldsymbol{x}_{ii}) \right) + \Omega(f_i) \tag{2}$$

式中 g_i——一阶导数 h_i——二阶导数

XGBoost 模型构建时参数选择很重要,通常分为通用参数、任务参数和辅助参数[23]。通用参数涵盖 booster、silent、nthread 等,用于设定模型基本运行环境和行为。辅助参数包括 eta、gamma、max_depth、subsample 等,这些参数直接影响模型训练效果和复杂度。任务参数为:objective、eval_metric、base_score 等,定义模型优化和评估标准。采用 XGBoost 模型常用的 Optuna 超参数寻优方法和交叉验证方法进行模型优化。XGBoost 模型训练过程主要有:①对实验数据归一化处理,按照比例 7∶3 划分为训练集和测试集。②将训练集按比例 5∶2 划分为训练与验证两部分,采用 5 折交叉验证法对训练集进行处理。③针对交叉验证的每份数据,XGBoost 模型分别建立树模型、寻找最优分裂点和计算目标函数等。④代入测试集验证预测精度。通过多次交叉验证以提升模型预测效果。

为了进一步探究 XGBoost 模型预测效果,对比其他集成学习方法,如 BP 神经网络(BPNN)[24]、多元线性回归(MLR)[25]和 Oh 模型[26]。BP 神经网络、MLR 和 Oh 模型训练过程参考 XGBoost 模型。

1.5 地质统计学方法

土壤含水率估测方法较多[13],统计学中常见的克里金插值技术在估测农田土壤含水率分布方面已有众多研究[27]。在实际应用中,土壤含水率空间变异情况可能会影响地理学统计方法预测精度;变异函数是衡量区域化变量空间变异结构或连续性的关键工具,构成了克里金插值法核心基础。合理评估变异函数并选择合适的插值技术可以减少空间变异的影响。基于区域化变量理论的框架及其内在假设,样本变异函数 $\gamma(h)$ 可通过特定数学模型进行计算[7],即

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (Z(x_i) - Z(x_i + h))^2 \tag{3}$$

式中 h——分离距离

x_i——样点在空间中的位置

$Z(x_i)$——实测值

$N(h)$——样本对数,确定样本变异函数值

为确保准确理解变量间的空间协变模式,涉及到多个变量时需分析协变异函数 $\gamma_{ij}(h)$,即

$$\gamma_{ij}(h) = \frac{1}{2N'(h)} \sum_{i'=1}^{N'(h)} (Z_1(x_i) - Z_1(x_i + h)) \cdot (Z_2(x_j) - Z_2(x_j + h)) \tag{4}$$

式中 $N'(h)$——$Z_1(x_i)$、$Z_2(x_j)$ 样本对数

如果变异函数分析表明变量之间存在显著的空间相关性,则可采用普通克里金插值对未知位置进行插值运算,即

$$z^*(x_0) = \sum_{i=1}^{n} \lambda_i z(x_i) \tag{5}$$

其中 $\sum \lambda_i = 1$

式中 $z^*(x_0)$——克里金插值法在 x_0 位置的预测值

$z(x_i)$——每个测量点实测值

λ_i——每个测量点对应权重

n——参与计算测量点数量

协同克里金插值不仅考虑预测变量,还引入其他相关变量作为辅助信息进行插值运算。预测变量被视为主变量,可计算变异函数;而其他辅助变量作为协变量,可计算协变异函数;在综合考虑主协变量变异函数基础上进行更为精确的无偏最优估计,计算式为

$$z^*(x_0) = \sum_{i=1}^{m} \lambda_{1i} z_i(x_i) + \sum_{j=1}^{q} \lambda_{2j} z_2(x_j) \tag{6}$$

其中 $\sum \lambda_{1i} = 1 \quad \sum \lambda_{2j} = 1$

式中 $z_1(x_i)$——主变量每个测量点实测值

$z_2(x_j)$——协变量每个测量点实测值

λ_{1i}、λ_{2j}——$z_1(x_i)$ 和 $z_2(x_j)$ 权重

m、q——主变量与协变量测量点数量

计算中用到两属性各自的变异函数和协变异函数[28]

$$\begin{cases} \sum_{i=1}^{m} \lambda_{1i} \gamma_{11}(x_{1i} - x_j) + \sum_{j=1}^{q} \lambda_{2j} \gamma_{21}(x_{2j} - x_j) + \mu_1 = \gamma_{11}(x_0 - x_j) \\ \sum_{i=1}^{m} \lambda_{1i} \gamma_{21}(x_{1i} - x_i) + \sum_{j=1}^{q} \lambda_{2j} \gamma_{22}(x_{2j} - x_i) + \mu_2 = \gamma_{21}(x_0 - x_i) \\ \sum_{i=1}^{m} \lambda_{1i} = 0 \\ \sum_{j=1}^{q} \lambda_{2j} = 1 \\ (i = 1,2,\cdots,m;\ j = 1,2,\cdots,q) \end{cases} \tag{7}$$

式中 μ_1、μ_2——常数

求解方程组(7)即可得到权重 λ_{1i} 和 λ_{2j},进而估算出 $z^*(x_0)$。

1.6　模型精度评价指标

通过决定系数(R^2)、均方根误差(RMSE)对土壤含水率反演模型精度进行评估,利用平均绝对误差(MAE)对插值结果进行评估[29]。通过相关系数(R)对变量间的相关程度进行评估。

2　结果与分析

2.1　土壤含水率特征统计

统计土壤表层与耕作层含水率均值、最值、标准差、变异系数等指标,结果如表 1 所示。两个剖面土层含水率变异系数大于 0.1 且小于 1,属于中等变异强度[30]。这与该地区虽存在大片农田,但也存在较小山坡,部分农田存在于山坡上,地势的高低起伏对土壤含水率垂直分布与横向迁移有显著影响有关。针对土壤剖面不同土层,土壤含水率分布地势影响机制不同,经过柯尔莫戈洛夫-斯米尔诺夫(Kolmogorov - Smirnov)检验,结果显示土壤含水率均服从正态分布,满足协同克里金插值条件。

表 1　土壤含水率统计

Tab. 1　Statistics of soil moisture content

土层	均值/($cm^3 \cdot cm^{-3}$)	最小值/($cm^3 \cdot cm^{-3}$)	最大值/($cm^3 \cdot cm^{-3}$)	标准差/($cm^3 \cdot cm^{-3}$)	偏度	峰度	变异系数	P	分布规律
表层	0.12	0.057	0.22	0.033	0.52	0.14	0.270 7	>0.200	正态分布
耕作层	0.14	0.065	0.23	0.034	0.26	-0.25	0.246 4	>0.200	正态分布

为了深入探究土壤含水率特性,分别将 2 剖面土层土壤含水率(115 个)随机划分为训练集(70%)和测试集(30%),分别包含 80 个样点和 35 个样点。对全集、训练集和测试集土壤含水率数据进行描述性统计分析,结果如图 2 所示。表层土壤含水率,全集、训练集、测试集均值分别为 0.123 1、0.124 1、0.120 8 cm^3/cm^3;标准差分别为 0.334、0.035 3、0.028 7 cm^3/cm^3。土壤耕作层含水率,全集、训练集、测试集土壤含水率均值分别为 0.139 8、0.140 0、0.139 2 cm^3/cm^3;标准差分别为 0.034 4、0.035 6、0.032 1 cm^3/cm^3。通过统计分析,全集、训练集和测试集土壤含水率分布相似,确保了样本具有代表性且避免了训练偏差。

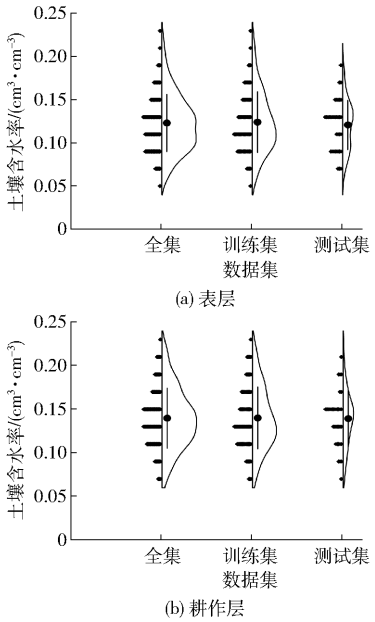

图 2　土壤含水率描述性统计

Fig. 2　Soil moisture content descriptive statistics

2.2　Sentinel - 1 数据反演土壤表层含水率

2.2.1　变量相关性与最优子集

对从 Sentinel 卫星数据提取的特征参数和土壤含水率实测数据进行相关性分析,结果如图 3 所示。由图 3 可知,后向散射系数 σ^0_{VH}($R=0.30$)、σ^0_{VV}($R=0.43$)、$\sigma^0_{VH}+\sigma^0_{VV}$($R=0.41$)、$\sigma^0_{VH}\times\sigma^0_{VV}$($R=0.38$)、$\sin(\theta)$($R=0.31$)、地形参数 DEM($R=0.28$)、表征目标散射机理平均散射角 α($R=0.30$)与土壤含水率相关性较大。表明本研究中后向散射系数、地形参数、α 等参数对土壤含水率影响较高,地形参数可表示入射角变化,$\sigma^0_{VH}/\sigma^0_{VV}$在角度一定情况下仅于地表粗糙度有关,与土壤含水率相关性并不高[31],选取的植被指数相关性较低,可能是因为研究区大部分农田为裸地;少部分农田存在冬小麦处于越冬期,对雷达散射影响较小。

综合考虑 R^2_{adj}、AIC、BIC 指数,将相关性较高的

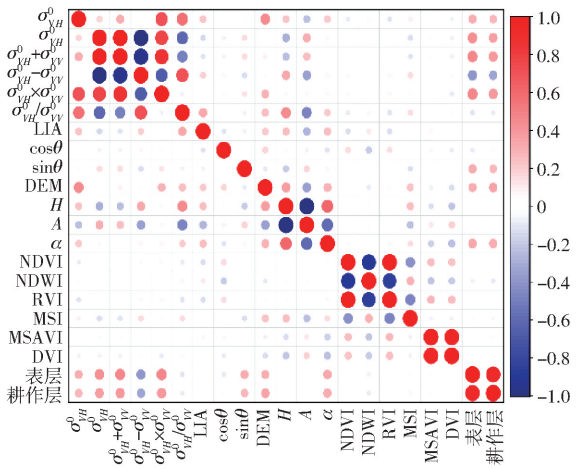

图 3　各变量与土壤含水率相关性分析

Fig. 3　Correlation analysis between various variables and soil moisture content

参数利用全子集筛选法筛选出土壤表层含水率反演的最优变量组合，结果表明特征参数为 σ^0_{VH}、σ^0_{VV}、$\sin\theta$、DEM、α 的组合 R^2_{adj} 为 0.284；BIC 值为 -5.64；AIC 值为 -4.98；该组合的 R^2_{adj} 在各个变量组合中最大，BIC 值最小，可作为最优变量组合。

2.2.2 土壤表层含水率反演模型建立

在最优组合变量下，将土壤表层含水率 115 个实测数据划分训练集（70%，80 个）和测试集（30%，35 个），对 4 类模型的适用性分别进行评估。图 4 为 4 类模型表层含水率反演精度。由图 4 可知，4 种模型预测值与实测值均具有较高的线性相关性。表 2 为 4 种模型表层含水率反演精度。由表 2 可知，4 种模型预测精度存在差异，XGBoost 模型决定系数最高，均方根误差最小，明显优于 Oh 模型、MLR 和 BP 神经网络；预测集中 XGBoost 模型精度评价指标优于其他 3 个模型；BP 神经网络 R^2 和 RMSE 都优于 MLR 和 Oh 模型，而 MLR 模型和 Oh 模型预测精度接近。4 种模型预测精度较建模集无明显下降。

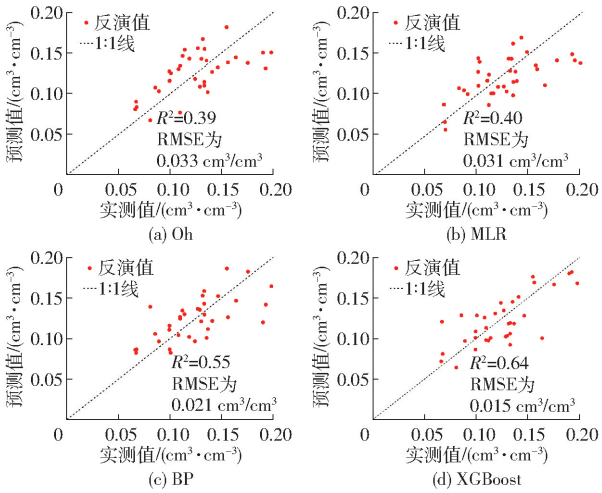

图 4 不同模型土壤表层含水率反演精度

Fig. 4 Inversion accuracy of soil surface moisture content in different models

表 2 土壤表层含水率反演模型及精度

Tab. 2 Soil surface moisture content inversion model and accuracy

模型	建模集		预测集	
	R^2	RMSE/($cm^3 \cdot cm^{-3}$)	R^2	RMSE/($cm^3 \cdot cm^{-3}$)
Oh	0.41	0.029	0.39	0.033
MLR	0.43	0.027	0.40	0.031
BP	0.57	0.018	0.55	0.021
XGBoost	0.66	0.012	0.64	0.015

综合评估建模集与验证集，4 种模型在预测性能和稳定性方面呈明显差异，XGBoost 模型展现出了较高的预测性能和稳定性，其次是 BP 神经网络，而 MLR 模型和 Oh 模型则相对较弱。土壤作为一个复杂的自然体系，土壤含水率同时受到多种环境因子的影响且作用程度各不相同。而 XGBoost 模型在构建过程中，不仅引入误差函数上的一阶和二阶导数，还通过迭代方式逐步优化模型预测能力，同时加入正则化项抑制过拟合[32]，充分考量了多种环境变量对土壤表层含水率的综合影响，表现出了强大的非线性映射能力和可靠的预测稳健性。模型综合比较来看，依靠数据驱动的 XGBoost 模型不依赖于单纯物理过程，预测效果优于 Oh 模型；XGBoost 模型避免了 MLR 其预测能力受限于线性假设的问题，同时克服了 BP 神经网络过拟合问题和模型性能受初始权重选择的影响较大、可能会陷入局部最小值。在对研究区土壤表层含水率进行模型预测精度评估中，XGBoost 模型展现出了显著的特征学习优越性和利用多变量预测土壤含水率空间分布的可行性。

经过综合评估和比较，XGBoost 模型是该地区土壤表层含水率反演最优模型，可以得到该区域表层含水率空间分布，像元分辨率为 10 m，如图 5 所示。

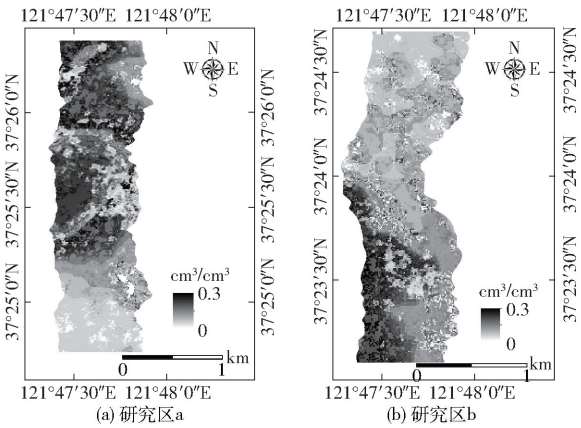

图 5 土壤表层含水率反演结果

Fig. 5 Inversion results of soil surface moisture content

2.3 协同克里金插值反演土壤耕作层含水率

2.3.1 样本变异函数计算

针对土壤表层和耕作层含水率，分析两剖面土层 115 个土壤含水率实测数据相关关系（图 6）；由图 6 可知，2 层含水率存在强正相关关系（R = 0.924 3）；采用统计学中常用的单样本柯尔莫戈洛夫-斯米尔诺夫法（Kolmogorov - Smirnov）对含水率进行分析，结果表明 2 组数据的 P 值均大于 0.05，符合正态分布特征。基于上述统计学分析，进一步提出利用协同克里金理论，对土壤含水率空间分布与变异性进行分析。

在研究区域 6.6 km^2 内，土壤表层含水率反演结

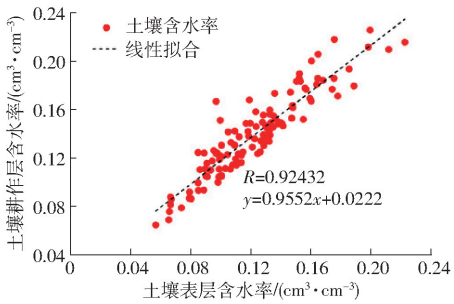

图 6　两层土壤含水率相关性分析

Fig. 6　Correlation analysis of soil moisture in two layers

果以象元分辨率 10 m 均匀分布，在研究区域产生了超过 1 000 个均匀分布的数据点。可以将有限的 115 个土壤耕作层含水率数据点作为主变量，大面积土壤表层含水率反演结果作为协变量，以补充耕作层含水率不足；采用协同克里金插值对耕作层含水率进行研究。

在实际测量中通过有限样本数量计算得到的变异函数值，常常会影响分析区域化变量的变异特性以及其结构性状。因此，通过变异函数进行推断，才能准确地描述变量在整个区域特征[33]。在实际应用中区域化变量变异特性复杂，不同方向上呈差异，也可能在某一方向上存在多尺度、多层次差异性。因此常采用多种理论模型来拟合变异函数，通过选择适当的理论模型，以来确保深入地捕捉区域化变量的空间变异结构。

为了深入探讨土壤含水率在各方向上可能存在的变异特征，在顺时针方向 30°、90°、150° 3 个不同方向上分别计算耕作层含水率和表层含水率变异函数值，如图 7 所示。由图 7 可知，在不同方向（30°、90°、150°，顺时针方向）上稳定距离一致，且变异函数值最终保持在 0.7 左右，认为土壤表层含水率在各个方向上变异特征一致。而土壤耕作层含水率可能是由于取样点不足，虽然在 3 个不同方向上的变异函数值最终稳定在 0.6 ~ 0.8，但变异性分析中的稳定距离表现并不显著，难以明确变异方向。另一方面，两剖面土层土壤含水率变异函数值都稳定在 0.7 左右，表明所选的样本点间距能够较为准确地反映土壤含水率空间变化特征。土壤表层含水率表现为各向同性，可将表层含水率作为耕作层含水率的补充，且认为两剖面土层含水率均呈各向同性特征。

半方差函数模型确定过程，目标是计算曲线的参数以最小化与点的偏差[34]。离差平方和是衡量 1 组数据变化程度的量，而通过计算所有已知点与其不同距离范围内邻居点集的离差平方和，可以大致衡量出已知点与不同距离范围邻居点的变化程度关系，常用方法为指数拟合、球面拟合、高斯拟合等；计算出半变异函数值 $\gamma(h)$ 对距离 h 的散点图，依据最小化与目标点偏差原则分别用不同类型模型来进行拟合，得到模型参数值及离差平方和，离差平方和越大表明拟合结果与不同距离范围内邻居点的差异程度越大，拟合效果越差[35]。

所选模型会影响未知值预测，尤其是在拟合过程中接近原点的曲线形状明显不同时。接近原点处曲线越陡，最接近的相邻元素对预测影响就越大，输出曲面将更不平滑。每个模型都用于更准确地拟合不同种类的现象。主变量与协变量的空间自相关性符合高斯模型，且协同区域化变量符合高斯模型，选择高斯模型描述三者的变异函数（图 8，C_0 为块金值，C 为偏基台值。L 为变程）。块金值反映误差和空间变异的存在，主协变量块金值均较小，表明表层和耕作层土壤受到外界环境因素干扰引起的变异小；块金系数均小于 25%，表示两变量空间自相关性较强[36]，说明由随机性因素引起的空间异质性在系统总变异中占比较小，在该地区进行协同克里金插值反演土壤含水率非常可靠。土壤含水率空间连续性受地形影响产生的分布范围为变程。变程受不同土壤物理属性或地域影响差异很大；当超出变程，土壤含水率空间相关性将不再显著。胡乐心等[37]研究表明土壤含水率变程为 8.40 ~ 18.47 m，

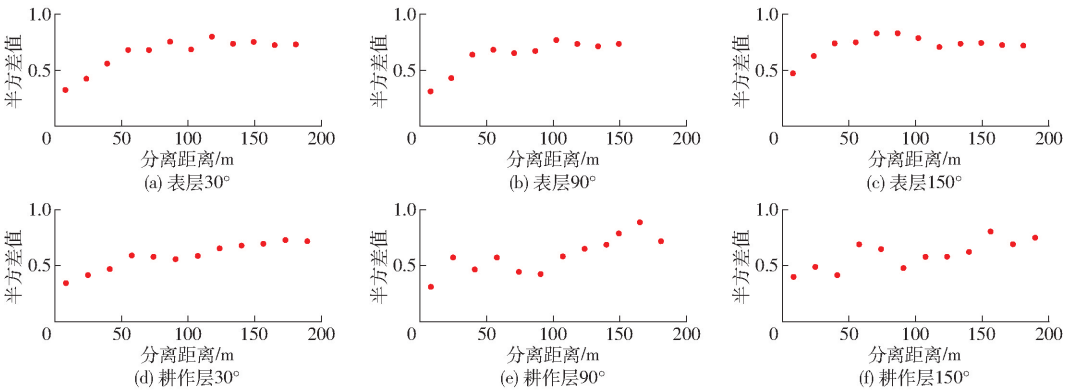

图 7　土壤表层与耕作层含水率在 30°、90°、150° 半变异函数值

Fig. 7　Semi variogram values of soil surface and tillage layer moisture content at 30°, 90° and 150°

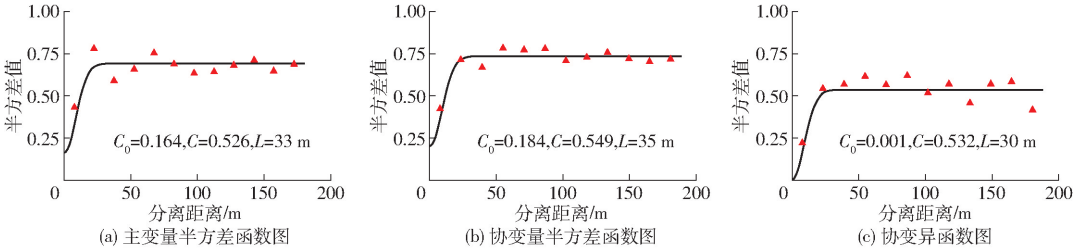

(a) 主变量半方差函数图 (b) 协变量半方差函数图 (c) 协变异函数图

图 8 高斯模型拟合的主变量和协变量半方差函数图

Fig. 8 Semi variance function plots of primary and covariate fitted by Gaussian model

WESTERN 等[33]研究表明变程为 35 ~ 60 m,谢正丰等[38]研究土壤体积含水率变程为 18.30 ~ 522.40 m,本文主变量和协变量的变程均稳定在 30 ~ 35 m 范围内。

2.3.2 协同克里金反演土壤耕作层含水率

基于上述理论,将土壤耕作层 115 个含水率实测数据作为主变量即 $z_1(x_{1i})$,将超过 1 000 个均匀分布的土壤表层含水率反演结果数据点作为协变量即 $z_2(x_{2j})$,代入式(6)进行协同克里金插值求解 $z^*(x_0)$,通过式(7)求解权重等参数;通过协同克里金插值得到研究区土壤耕作层含水率分布结果及精度如图 9 所示。

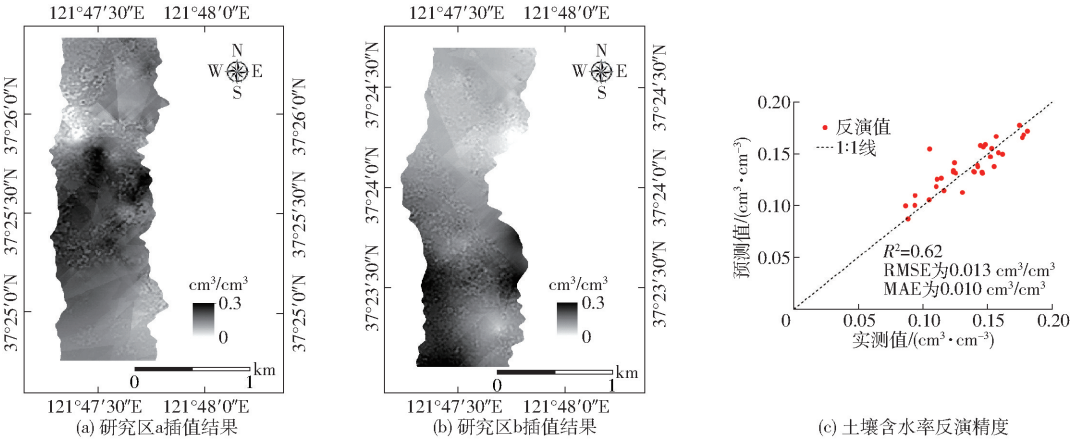

(a) 研究区a插值结果 (b) 研究区b插值结果 (c) 土壤含水率反演精度

图 9 协同克里金土壤耕作层含水率插值结果

Fig. 9 Co-Kriging interpolation results of soil tillage layer moisture content

将协同克里金插值结果与土壤耕作层含水率克里金插值结果(图 10),和基于土壤表层与耕作层的相关关系推导的土壤耕作层含水率双线性插值(图 11)结果进行对比。结果表明,图 9a 中部地区土壤耕作层含水率在 0.11 ~ 0.18 cm^3/cm^3 的网格偏多,图 9b 南部地区土壤耕作层含水率在 0.15 cm^3/cm^3 以上的网格偏多。结合当地实际情况来看,种植冬小麦农田主要分布在研究区 a 中部地区,并且该地区也存在刚收割的农田,可能导致该地区土壤含水率较其他地区高。研究区 b 裸地较多土质种类相对均匀,但南部部分地区也存在地势的起伏,这可能是影响土壤含水率分布不均匀的主要因素之一,整体呈现

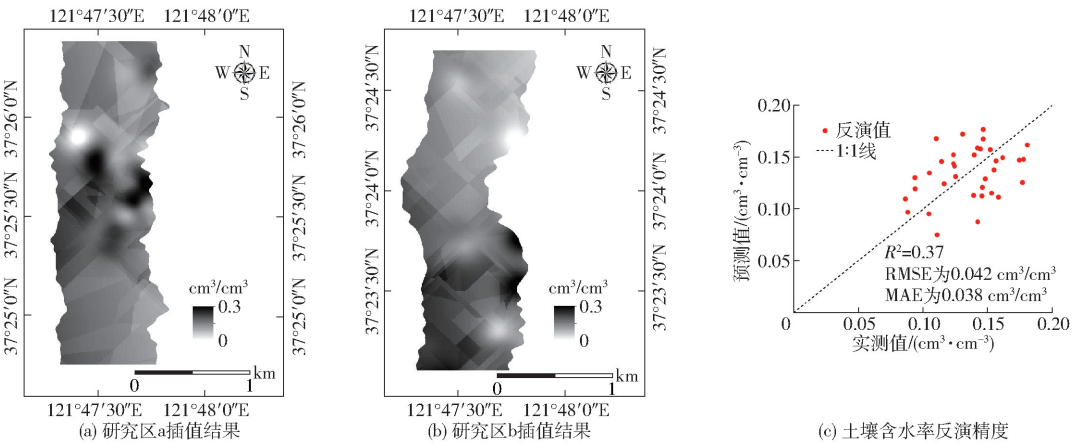

(a) 研究区a插值结果 (b) 研究区b插值结果 (c) 土壤含水率反演精度

图 10 克里金土壤耕作层含水率插值结果

Fig. 10 Kriging interpolation results of soil tillage layer moisture content

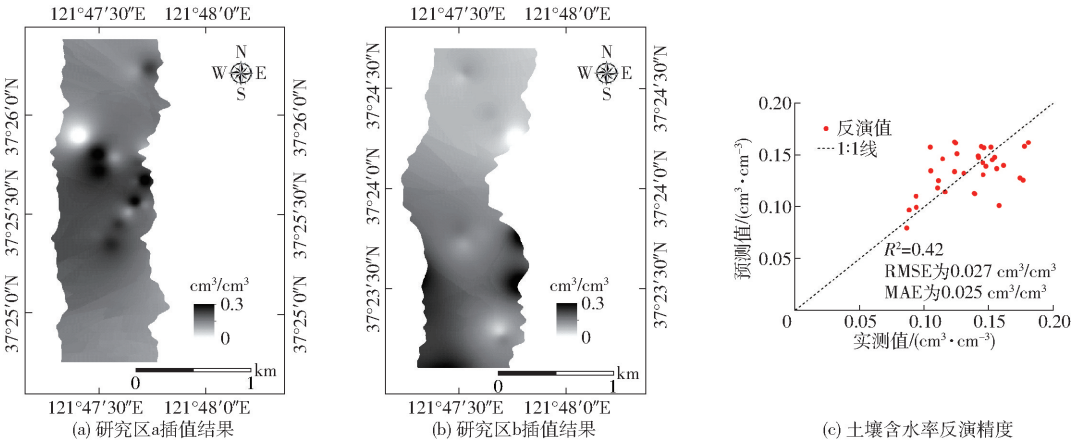

(a) 研究区a插值结果　(b) 研究区b插值结果　(c) 土壤含水率反演精度

图 11　双线性土壤耕作层含水率插值结果

Fig. 11　Bilinear interpolation results of soil tillage layer moisture content

北低南高的分布趋势。3 种结果土壤含水率分布趋势一致，且图 9 决定系数 R^2 分别比图 10 和图 11 高 0.25 和 0.20，均方根误差 RMSE 分别降低 0.029、0.014 cm^3/cm^3，平均绝对误差 MAE 分别降低 0.028、0.015 cm^3/cm^3 表明协同克里金插值的结果均优于克里金插值的结果和相对于点尺度的双线性插值结果。

3　结论

（1）C 波段极化 SAR 雷达数据可以很好地反映土壤表层信息，利用 Sentinel－1 卫星搭载的 C 波段雷达数据对土壤表层含水率进行分析时，发现土壤表层含水率与多个参数变量之间的相关性存在差异。后向散射系数 σ^0_{VH}、σ^0_{VV}、$\sigma^0_{VH}\times\sigma^0_{VV}$、$\sigma^0_{VH}+\sigma^0_{VV}$、$\sin\theta$、地形参数 DEM、表征目标散射机理平均散射角 α 对土壤含水率相关性较大。综合考虑 R^2_{adj}、AIC、BIC 等指数，利用最优子集筛选法筛选结果表明特征参数为 σ^0_{VH}、σ^0_{VV}、$\sin\theta$、DEM、α 可作为土壤表层含水率反演最优的自变量组合。

（2）对土壤表层含水率反演模型比较，结果表明基于最优子集筛选的 XGBoost 模型（$R^2=0.64$）精度高于 BP 神经网络（$R^2=0.55$）、MLR 模型（$R^2=0.40$）和 Oh 模型（$R^2=0.39$）。选择 XGBoost 模型反演研究区土壤表层含水率，验证集精度 $R^2=0.64$，RMSE 为 0.015 cm^3/cm^3。

（3）对土壤表层含水率进行空间分析，在不同方向（30°、90°、150°，顺时针方向）上稳定距离一致，变异函数值最终保持在 0.7 左右，基本符合各向同性。耕作层含水率变异方向不明显。将表层含水率结果作为协变量，可以弥补作为主变量的耕作层含水率在变异方向上不显著和数据稀缺的问题。协同克里金插值反演土壤耕作层含水率 $R^2=0.62$，RMSE 为 0.013 cm^3/cm^3，MAE 为 0.010 cm^3/cm^3。与土壤耕作层含水率普通克里金插值（$R^2=0.37$）和双线性插值（$R^2=0.42$）相比较，结果明显提高。

参　考　文　献

[1]　刘会丹，万雪芬，崔剑，等. 基于深度强化学习的耕作层土壤水分、温度预测[J]. 华南农业大学学报，2023，44(1)：84－92.
LIU Huidan，WAN Xuefen，CUI Jian，et al. Moisture and temperature prediction in tillage layer based on deep reinforcement learning[J]. Journal of South China Agricultural University，2023，44(1)：84－92.（in Chinese）

[2]　马若飞，伟利国，赵博，等. 基于多传感器数据融合的旋耕深检测系统研究[J]. 农业机械学报，2024，55(9)：52－64.
MA Ruofei，WEI Liguo，ZHAO Bo，et al. Rotary tillage depth detection based on multi-sensor data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(9)：52－64.（in Chinese）

[3]　马欢，岳德鹏，YANG Di，等. 基于数据同化的地下水埋深插值研究[J]. 农业机械学报，2017，48(4)：206－214.
MA Huan，YUE Depeng，YANG Di，et al. Interpolation of groundwater depth based on data assimilation[J]. Transactions of the Chinese Society for Agricultural Machinery，2017，48(4)：206－214.（in Chinese）

[4]　李勇，赵云泽，勾宇轩，等. 黄淮海旱作区农田耕层土壤结构特征与其影响因素[J]. 农业机械学报，2022，53(3)：321－330.
LI Yong，ZHAO Yunze，GOU Yuxuan，et al. Characteristics and influencing factors of topsoil structure of farmland in dry farming region of Huang－Huai－Hai[J]. Transactions of the Chinese Society for Agricultural Machinery，2022，53(3)：321－330.（in Chinese）

[5]　REICHLE R H，LIU Q，KOSTER R D，et al. Version 4 of the SMAP Level－4 soil moisture algorithm and data product[J]. Journal of Advances in Modeling Earth Systems，2019，11(10)：3106－3130.

[6]　KORNELSEN K C，COULIBALY P. Root-zone soil moisture estimation using data driven methods[J]. Water Resource

Research, 2014, 50(4): 2946 – 2962.

[7] 徐驰,曾文治,黄介生,等. 基于高光谱与协同克里金的土壤耕作层含水率反演[J]. 农业工程学报, 2014, 30(13): 94 – 103.
XU Chi, ZENG Wenzhi, HUANG Jiesheng, et al. Modelling soil water content in plow layer using co-Kriging interpolation based on hyperspectral data[J]. Transactions of the CSAE, 2014, 30(13): 94 – 103. (in Chinese)

[8] TIAN J, HAN Z B, BOGENA H R, et al. Estimation of subsurface soil moisture from surface soil moisture in cold mountainous areas[J]. Hydrology and Earth System Sciences, 2020, 24(9): 4659 – 4674.

[9] 田静. 基于指数滤波法的中国区域深层土壤水分估算[J]. 中国农业大学学报, 2024, 29(5): 149 – 158.
TIAN Jing. Estimation of subsurface soil moisture in China based on exponential filtering method[J]. Journal of China Agricultural University, 2024, 29(5):149 – 158. (in Chinese)

[10] 吴代晖,范闻捷,崔要奎,等. 高光谱遥感监测土壤含水量研究进展[J]. 光谱学与光谱分析, 2010, 30(11): 3067 – 3071.
WU Daihui, FAN Wenjie, CUI Yaokui, et al. Review of monitoring soil water content using hyperspectral remote sensing[J]. Spectroscopy and Spectral Analysis, 2010, 30(11): 3067 – 3071. (in Chinese)

[11] 陈俊英,项茹,贺玉洁,等. 基于 Landsat8 与 Sentinel – 1 遥感图像融合的土壤含水率反演模型[J]. 农业机械学报, 2024, 55(2): 208 – 219.
CHEN Junying, XIANG Ru, HE Yujie, et al. Soil moisture content inversion model based on Landsat8 and Sentinel – 1 image fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 208 – 219. (in Chinese)

[12] 靳亚红,吴鑫淼,甄文超,等. 基于采样点光谱信息窗口尺度优化的土壤含水率无人机多光谱遥感反演[J]. 农业机械学报, 2024, 55(1): 316 – 327.
JIN Yahong, WU Xinmiao, ZHEN Wenchao, et al. UAV multispectral remote sensing inversion of soil moisture content based on window size optimization of spectral information at sampling points[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 316 – 327. (in Chinese)

[13] 杨雨亭,尚松浩,李超. 土壤水分空间插值的克里金平滑效应修正方法[J]. 水科学进展, 2010, 21(2): 208 – 213.
YANG Yuting, SHANG Songhao, LI Chao. Correcting the smoothing effect of ordinary Kriging estimates in soil moisture interpolation[J]. Advances in Water Science, 2010, 21(2): 208 – 213. (in Chinese)

[14] VAUGHAN P J, LESCH S M, CORWIN D L, et al. Water content effect on soil salinity prediction: a geostatistical study using cokriging[J]. Soil Science Society of America Journal, 1995, 59(4): 1146 – 1156.

[15] 郭交,刘健,宁纪锋,等. 基于 Sentinel 多源数据的农田地表土壤水分反演模型构建与验证[J]. 农业工程学报, 2019, 35(14):71 – 78.
GUO Jiao, LIU Jian, NING Jifeng, et al. Construction and validation of soil moisture retrieval model in farmland based on Sentinel multi-source data[J]. Transactions of the CSAE, 2019, 35(14): 71 – 78. (in Chinese)

[16] LEE J S, GRUNES M R, DE GRANDI G. Polarimetric SAR speckle filtering and its implication for classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(5): 2363 – 2373.

[17] 单子力,刘翔,陈旸,等. 双极化 SAR 图像 H/α 分解及替代方法研究[J]. 无线电工程, 2013, 43(12): 32 – 36.
SHAN Zili, LIU Xiang, CHEN Yang, et al. H/α Decomposition and alternative method for dual polarization SAR imagery [J]. Radio Engineering, 2013, 43(12): 32 – 36. (in Chinese)

[18] 林利斌. 多源遥感数据反演植被覆盖地表土壤水分方法研究[D]. 南京:南京信息工程大学, 2018.
LIN Libin. Soil moisture retrieval under vegetation cover using multi-source remote sensing data[D]. Nanjing: Nanjing University of Information Science and Technology, 2018. (in Chinese)

[19] 赵建辉,张晨阳,闵林,等. 基于特征选择和 GA – BP 神经网络的多源遥感农田土壤水分反演[J]. 农业工程学报, 2021, 37(11): 112 – 120.
ZHAO Jianhui, ZHANG Chenyang, MIN Lin, et al. Surface soil moisture in farmland using multi-source remote sensing data and feature selection with GA – BP neural network[J]. Transactions of the CSAE, 2021, 37(11): 112 – 120. (in Chinese)

[20] 王大成,王纪华,靳宁,等. 用神经网络和高光谱植被指数估算小麦生物量[J]. 农业工程学报, 2008, 24(增刊2): 196 – 201.
WANG Dacheng, WANG Jihua, JIN Ning, et al. ANN-based wheat biomass estimation using canopy hyperspectral vegetation indices[J]. Transactions of the CSAE, 2008, 24(Supp. 2): 196 – 201. (in Chinese)

[21] 张智韬,韩佳,陈皓锐,等. 基于全子集分位数回归的土壤含盐量反演研究[J]. 农业机械学报, 2019, 50(10): 142 – 152.
ZHANG Zhitao, HAN Jia, CHEN Haoyue, et al. Soil salinity inversion based on best subsets-quantile regression model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(10): 142 – 152. (in Chinese)

[22] JAMSHIDI E J, YUSUP Y, HOOY C W, et al. Predicting oil palm yield using a comprehensive agronomy dataset and 17 machine learning and deep learning models[J]. Ecological Informatics, 2024, 81: 102595

[23] SOMALA S N, CHANDA S, Al HMAMYDEH M, et al. Explainable XGBoost – SHAP machine-learning model for prediction of ground motion duration in New Zealand[J]. Natural Hazards Review, 2024, 25(2): 04024005.

[24] ADENIYI J K, ADENIYI T, AJAGBE S A, et al. Acomparative analysis of the performance of deep learning techniques in precision farming using soil and climate factors[J]. Procedia Computer Science, 2024, 235: 2812 – 2821.

[25] 马仪,黄组桂,贾江栋,等. 基于无人机-卫星遥感升尺度的土壤水分监测模型研究[J]. 农业机械学报, 2023, 54(6):

307 – 318.
MA Yi, HANG Zugui, JIA Jiangdong, et al. Soil moisture monitoring model based on UAV – satellite remote sensing scale-up [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 307 – 318. (in Chinese)

[26] OH Y, SARA BAND I K, ULABY F T. An empirical model and an inversion technique for radar scattering from bare soil surface[J]. IEEE Transaction on Geoscience and Remote Sensing, 1992,30(2): 370 – 381.

[27] YATES S R, WARRICK A W. Estimating soil water content using cokriging[J]. Soil Science Society of America Journal, 1987, 51(1): 23 – 30.

[28] 胡丹桂,舒红. 基于协同克里金空气湿度空间插值研究[J]. 湖北农业科学, 2014, 53(9): 2045 – 2049.
HU Dangui, SHU Hong. Air humidity based on co Kriging interpolation[J]. Hubei Agricultural Sciences, 2014, 53(9): 2045 – 2049. (in Chinese)

[29] 张自豪,王国强,薛宝林,等. 基于深度学习方法预测缺资料区域深层土壤水分[J]. 水利水电技术(中英文), 2022, 53(11):25 – 36.
ZHANG Zihao, WANG Guoqiang, XUE Baolin, et al. Deep learning method-based prediction of deep soil moisture in data-deficient water shed[J]. Water Resources and Hydropower Engineering, 2022, 53(11): 25 – 36. (in Chinese)

[30] 张继光,陈洪松,苏以荣,等. 喀斯特峰丛洼地坡面土壤水分空间变异研究[J]. 农业工程学报, 2006, 22(8): 54 – 58.
ZHANG Jiguang, CHEN Hongsong, SU Yirong, et al. Spatial variability of soil moisture on hillslope in cluster-peak depression areas in Karst region[J]. Transactions of the CSAE, 2006, 22(8):54 – 58. (in Chinese)

[31] 关韵桐,李金平. 基于遗传优化神经网络的多源遥感数据反演土壤水分[J]. 水资源与水工程学报, 2019, 30(2): 252 – 256.
GUAN Yuntong, LI Jinping. Soil moisture inversion based on genetic optimization neural network and multi-source remote sensing data[J]. Journal of Water Resources & Water Engineering, 2019, 30(2): 252 – 256. (in Chinese)

[32] JIA Y, JIN S, SAVI P, et al. GNSS – R soil moisture retrieval based on a XGboost machine learning aided method: performance and validation[J]. Remote Sensing, 2019, 11(14):1655.

[33] WESTERN A W, BLÖSCHL G, GRAYSON R B. Geostatistical characterisation of soil moisture patterns in the Tarrawarra catchment[J]. Journal of Hydrology, 1998, 205(1/2): 20 – 37.

[34] 王军,傅伯杰,邱扬,等. 黄土丘陵小流域土壤水分的时空变异特征——半变异函数[J]. 地理学报, 2000, 55(4): 428 – 438.
WANG Jun, FU Bojie, QIU Yang, et al. Spatiotemporal variability of soil moisture in small catchment on loess plateau—semivariograms[J]. Acta Geographica Sinica, 2000, 55(4): 428 – 438. (in Chinese)

[35] 胡克林,李保国,林启美,等. 农田土壤养分的空间变异性特征[J]. 农业工程学报, 1999, 15(3): 33 – 38.
HU Kelin, LI Baoguo, LIN Qimei, et al. Spatial variability of soil nutrient in wheat field[J]. Transactions of the CSAE, 1999, 15(3): 33 – 38. (in Chinese)

[36] SAYED Y A, KHALAFALLA M Y. Using GIS and geostatistics to monitoring spatial variability in soil chemical properties impacted by cultivation practices[J]. Journal of Soil Sciences and Agricultural Engineering, 2024, 15(4): 93 – 98.

[37] 胡乐心,刘目兴,赵露,等. 长江三峡山地集水区土壤水分空间变异特征[J]. 水土保持学报, 2023, 37(5): 86 – 93.
HU Lexin, LIU Muxing, ZHAO Lu, et al. Spatial variation characteristics of soil moisture in the Three Gorges Mountain catchment area of the Yangtze River[J]. Journal of Soil and Water Conservation, 2023, 37(5):86 – 93. (in Chinese)

[38] 谢正丰,王冬梅,张鹏,等. 黄土高寒区小流域土壤水分空间变异与环境影响因子[J]. 水土保持学报, 2022, 36(4): 196 – 203.
XIE Zhengfeng, WANG Dongmei, ZHANG Peng, et al. Spatial variation of soil moisture and its environmental influencing factors in a small watershed in the loess alpine region[J]. Journal of Soil and Water Conservation, 2022, 36(4): 196 – 203. (in Chinese)