

黄浦, 黄青, 王经天, 石宇涵, 蔡盛红. 中国东北地区土壤黏化层厚度的数字制图[J]. 土壤学报, 2026,

HUANG Pu, HUANG Qing, WANG Jingtian, SHI Yuhan, CAI Shenghong. Digital Mapping of Soil Argillic Horizon Thickness in Northeast China[J]. Acta Pedologica Sinica, 2026,

## 中国东北地区土壤黏化层厚度的数字制图\*

黄浦, 黄青<sup>†</sup>, 王经天, 石宇涵, 蔡盛红

(北方干旱半干旱耕地高效利用全国重点实验室/中国农业科学院农业资源与农业区划研究所, 北京 100081)

**摘要:** 黏化层是由土壤黏粒显著积累而形成的次生层, 其厚度影响着淋溶土的土壤过程和植被生长。但迄今对黏化层的空间分布变化了解有限, 对其预测报道也甚少。传统的认知主要依赖大规模实地调查与地统计学方法结合。为快速获取大范围的黏化层厚度空间信息, 本研究将我国东北三省 311 个含黏化层的土壤剖面样点与环境协变量(地形、气候、生物和土壤因子共 71 个变量)相结合, 构建了一个相对可靠的预测模型。使用 Pearson 相关性分析和 Boruta 算法进行双重特征筛选后, 采用分位数回归森林(Quantile regression forest, QRF)模型进行空间建模、交叉验证和不确定性估计。50 次迭代的平均结果显示, 模型预测的决定系数( $R^2$ )为 0.32, 均方根误差(Root mean square error, RMSE)为 24.34 cm, 平均绝对误差(Mean absolute error, MAE)为 19.47 cm。预测区间覆盖概率(Prediction interval coverage percentage, PICP)显示, 约有 86.2%的验证样本落在预定义的 90% PI 范围内, 这表明不确定性估计很大程度上是可靠的。在建模过程中, 土壤变量和气候变量的重要性普遍高于生物变量和地形变量, 其中土壤厚度(Soil thickness, ST)是最核心的驱动因子。相应的预测结果显示, 在研究区内黏化层厚度沿西南—东北方向呈递减趋势。缺乏土壤调查点的地区具有较大的预测不确定性, 后续研究应在这些区域进行适当的补充调查。该研究成果对于东北地区土地管理政策优化具有一定的指导意义。

**关键词:** 数字土壤制图; 土壤—景观理论; 土壤黏化层; 特征筛选; 分位数回归森林模型; 不确定性估计

中图分类号: S159

文献标志码: A

### Digital Mapping of Soil Argillic Horizon Thickness in Northeast China

HUANG Pu, HUANG Qing<sup>†</sup>, WANG Jingtian, SHI Yuhan, CAI Shenghong

(State Key Laboratory of Efficient Utilization of Arable Land in China / Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

**Abstract:** **【Objective】**The argillic horizon is a subsurface secondary layer formed by the accumulation of soil clay particles, and its thickness exerts a crucial regulatory effect on soil processes and vegetation growth in Alfisols. Understanding its spatial distribution is critical for effective land management, particularly in agriculturally important regions such as Northeast China. However, there is still limited knowledge of the spatial variability in argillic horizon thickness, and predictive studies on this topic are scarce. Traditional understanding has largely relied on extensive field surveys combined with geostatistical methods, which are often resource-intensive and may not be efficient over large regions. This study aims to develop a robust predictive model to map the spatial distribution of argillic horizon thickness across the three northeastern provinces of China by integrating limited soil profile observations with a rich set of environmental covariates. **【Method】**A total of 311 soil

\* 国家重点研发计划项目(2023YFD1500102)和中央级公益性科研院所基本科研业务费专项(1610132024007)资助 Supported by the National Key Research and Development Program (No. 2023YFD1500102) and the Fundamental Research Funds for Central Non-profit Scientific Institution (No. 1610132024007)

<sup>†</sup> 通讯作者 Corresponding author, E-mail: huangqing@caas.cn

作者简介: 黄浦(2001-), 男, 四川内江人, 硕士研究生, 主要从事数字土壤制图研究。E-mail:2209913206@qq.com

收稿日期: 2025-07-04; 收到修改稿日期: 2026-02-02; 网络首发日期(www.cnki.net):

profile samples with argillic horizons were collected in Northeast China. These samples incorporated data from recent field surveys and historical soil records. Consistent with the SCORPAN framework, 71 environmental covariates were selected to correspond to relief, climate, organism, and soil factors. Dual feature selection was conducted via Pearson correlation analysis and the Boruta algorithm. The quantile regression forest (QRF) model was then adopted for spatial modeling, cross-validation, and uncertainty estimation. Rigorous evaluation of model performance and uncertainty estimation was conducted through 50 repetitions of 10-fold cross-validation, and accumulated local effects (ALE) plots were generated to interpret the relationship between key predictors and the target variable. **【Result】** The average results from 50 iterations showed that the model achieved a coefficient of determination ( $R^2$ ) of 0.32, a root mean square error (RMSE) of 24.34 cm, and a mean absolute error (MAE) of 19.47 cm. This performance is significantly superior to that of most regional and national scale soil thickness prediction studies ( $R^2 = 0.11-0.41$ ). The prediction interval coverage percentage (PICP) was 86.2%, which is close to the predefined 90% prediction interval (PI), indicating high reliability of the uncertainty estimation. Soil and climate factors were generally more influential than organism and relief factors, with soil thickness (ST) identified as the most critical driving factor. The spatial prediction results indicated a distinct decreasing trend in argillic horizon thickness from the southwest to the northeast. The western and southwestern regions of the study area exhibited the thickest argillic horizons (mostly over 80 cm, with some regions ranging from 100 to 125 cm), while the northern, eastern, and southeastern regions had thinner ones (mostly 20–35 cm, with some regions below 20 cm). High prediction uncertainty was concentrated in mountainous and hilly regions with sparse soil survey points. **【Conclusion】** This study confirms the feasibility of mapping argillic horizon thickness using a machine learning approach combined with environmental covariates, even in large, complex landscapes with limited soil observations. Future research could focus on integrating proxies for parent material and pedogenic age to enhance model accuracy, as well as exploring the spatial prediction of other argillic horizon properties (e.g., upper boundary and compactness). This study not only addresses the gap in argillic horizon thickness prediction in Northeast China, but also offers valuable insights for optimizing regional land management strategies.

**Key words:** Digital soil mapping; Soil-landscape theory; Soil argillic horizon; Feature selection; Quantile regression forest model; Uncertainty estimation

黏化层是一种广泛存在的土壤层, 据统计, 具有黏化层的土壤占地球表面土壤的 25% 以上<sup>[1-2]</sup>。这种底土黏粒富集层的存在是诊断淋溶土的首要标准<sup>[3]</sup>, 其形成主要归因于土壤中的黏粒在特定环境条件下的迁移和淀积<sup>[4-6]</sup>。其中, 黏化层厚度是淋溶土的一项重要土壤属性, 它对该土纲的许多地表和地下土壤过程有着较强的控制作用。例如, 厚度适中的黏化层能够赋予土壤良好的保水保肥能力<sup>[2,4]</sup>, 为植物根系提供一个稳定的锚定层; 但如果厚度过厚, 可能导致形成致密的隔水层, 阻碍根系下扎和气体交换, 引发作物烂根, 最终演化成一种土壤障碍层。目前, 现有研究尚未明确将其视作土壤障碍层的厚度阈值, 但对黏化层厚度空间分布的揭示可以指导土壤分区管理和保护性利用技术模式的精准配置, 尤其是在中国土壤最为肥沃的东北地区。

以往的土层厚度(或深度)预测制图研究中<sup>[7-8]</sup>, 经典统计学和地统计学发挥了主要作用。自土壤—景观关系理论提出以来, 人们开始将难以获取的土壤信息与一些相对容易获取的成土环境因素联系起来, 并利用这些环境因素来推断土壤信息的空间变化<sup>[9-10]</sup>。然而, 大多制图研究的关注重点都是土壤的理化属性, 如 pH、有机碳、质地、容重、氮磷钾含量等, 对土层厚度(或深度)空间预测制图的研究报道并不多, 一个重要的原因在于其预测难度大且精度往往不高。部分学者使用基于机器学习的数字土壤制图技术, 在土壤(或土层)厚度(或深度)的空间预测方面做出了尝试。例如, Dharumarajan 等<sup>[11]</sup>收集 5174 个土壤剖面样点, 使用分位数回归森林(Quantile regression forest, QRF)和回归克里格(Regression kriging, RK)两种模型在印度的 Karnataka 地区绘制了土壤深度地图; Chen 等<sup>[12]</sup>使用 10978 个土壤剖面样点并结合 QRF, 在法国中部的一个集约化耕作区域进行黄土沉积层厚度的空间分布预测和不确定性预测制图; Liu 等<sup>[13]</sup>使用 275 个土壤剖面样点, 在黑河流域建立了一个相对可靠的基于 QRF 的土壤深度预测模型; 陈玉蓝等<sup>[14]</sup>基于 294 个土壤剖面样点, 使用

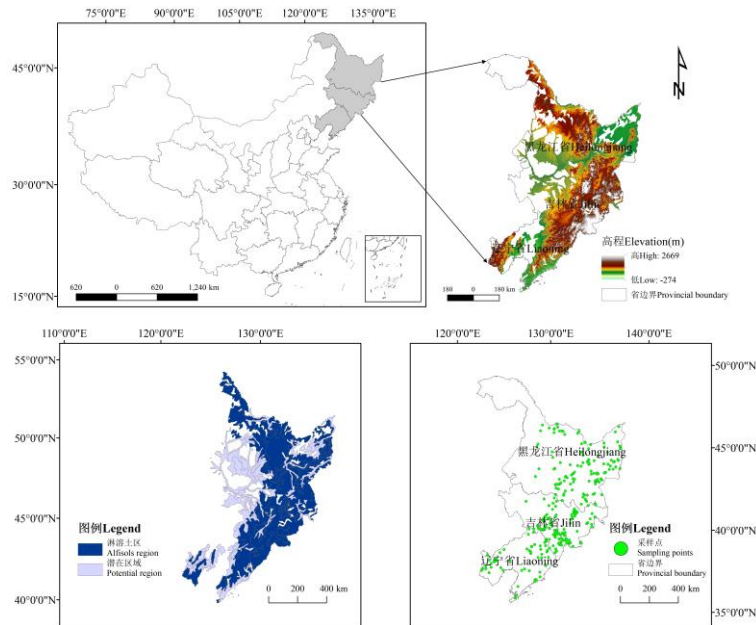
支持向量机 (Support vector machine, SVM)、随机森林 (Random forest, RF) 和 QRF 三种模型分别对四川省的土壤厚度进行了独立预测、集成预测以及特征集成预测。相比之下,黏化层作为土体中的特征土层,因其涉及的影响因素更为复杂,其厚度预测无疑更难于土体厚度的预测,这应该是至今有关黏化层厚度预测的研究甚少的根本原因。

构建高精度的空间预测模型通常需要大量的土壤样点数据<sup>[15-17]</sup>,但对幅员辽阔的我国东北三省而言,实地调查采样分析的高成本限制了可获取的土壤样点数量。而且,中国东北地区大部分为景观复杂的农作区,易于获取的地形和植被等信息在许多情形下均不能很好地反映土壤的空间变异<sup>[18-20]</sup>,如何选择合适的环境协变量实现黏化层厚度的高精度预测无疑是一个挑战。为此,本研究旨在利用我国东北三省有限的实地剖面数据,建立一个相对可靠的土壤黏化层厚度预测模型。

## 1 材料与方 法

### 1.1 研究区概况

研究区为中国东北的黑龙江、吉林和辽宁三省,主要属温带季风气候,冬季寒冷漫长、夏季温暖短暂,且降水多集中在夏季,这种特殊的水热条件为黏粒的运移过程提供了保障<sup>[6]</sup>。本研究区的土壤类型较为丰富,其中土壤黏化层通常出现在淋溶土土纲的白浆土、暗棕壤、棕壤、黄褐土、黄棕壤和灰化土等土类中。结合《1:100万中华人民共和国土壤图》数字化生成的中国土壤类型空间分布图<sup>[21]</sup>,本研究确定了淋溶土的空间分布范围。但在该土壤类型图的非淋溶土图斑上仍发现了一些具有黏化层特征(参照《中国土壤系统分类检索(第三版)》<sup>[22]</sup>进行判别)的土壤剖面,这很可能是因为该土壤类型图相对陈旧导致的。为解决这一问题,当含黏化层的土壤剖面样点落在非淋溶土图斑时,将这些图斑列为黏化层可能存在的潜在区域。详细的分布信息如图1所示。



注:该图基于自然资源部标准地图服务下载的审图号为GS(2024)0650号的标准地图制作,底图无修改。Note: This map was based on the standard map downloaded from the standard map service of the Ministry of Natural Resources with the review map number GS(2024)0650, and the base map was not modified.

图1 研究区土壤剖面样点的空间分布(以彩图发表)

Fig. 1 Spatial distribution of sampling profile points in the study area

### 1.2 土层数据

本研究于 2023—2024 年开展了一次全面的东北三省土壤调查工作。该调查以全国第二次土壤普查的土壤图斑为基础, 结合土地利用现状、地形(高程、坡度)、NDVI 标准差、Landsat 7 的 Band 5、地貌及成土母质等多源环境变量数据, 通过空间叠置分析生成了综合性的地理斑块。在此基础上, 考虑道路的可达性, 根据地形起伏度划分道路的可达范围(低起伏区 1000 m 缓冲区内认为可达, 高起伏区 200 m 缓冲区内认为可达), 进而筛选符合条件的候选斑块; 然后, 将所有的候选斑块按照面积大小进行排序; 最后, 样点的布设优先考虑大面积且属于淋溶土纲的斑块, 以确保有限的样点能最大限度地覆盖东北三省的所有典型景观和土壤类型, 最大限度地提高调查结果的代表性和空间覆盖度。共布设了 213 个含黏化层的土壤剖面点。

在地面调查点, 使用手持 GPS 对采样点位置进行精确定位, 并逐一挖掘土壤剖面, 直至母质层或母岩层。黏化层的野外判断依据主要是层次的手感质地差异以及土壤结构体表面黏粒胶膜的存在与否, 后期再依据颗粒组成测定结果中的黏粒含量, 参考《中国土壤系统分类检索(第三版)》<sup>[22]</sup>中黏化层的划分标准进行验证。

此外, 为增加建模样点, 本研究还整理了《中国土系志·黑龙江卷》<sup>[23]</sup>、《中国土系志·吉林卷》<sup>[24]</sup>和《中国土系志·辽宁卷》<sup>[25]</sup>记录的 390 个典型土壤剖面, 这些剖面的采集时间为 2010—2018 年。从中筛选出了 98 个具有黏化层特征的土壤剖面, 并将这些剖面信息与野外实地调查数据相结合, 最终构建了一个包含 311 个有效观测的土壤黏化层空间数据库。具体的采样位置如图 1 所示。

### 1.3 环境协变量

根据土壤—景观关系理论, 环境协变量的选择遵从 SCORPAN 理论范式<sup>[9]</sup>。然而, 直接将母质因素或时间因素纳入环境协变量中依旧是一个科学难题, 目前尚未得到显式突破<sup>[26]</sup>, 故这两个因子在本研究中暂不考虑。最终, 从地形、气候、生物和土壤因子 4 个方面选取环境协变量, 协变量的具体信息如表 1 所示。

(1) 气候因子变量来源一是中国科学院成都山地灾害与环境研究所的高分辨率山地环境制图的数据产品, 共 23 个气候因子, 均为 1990s—2010s 的均值, 初始分辨率为 30 m; 来源二是中国科学院资源环境科学数据平台(<https://www.resdc.cn/>)的共享数据, 共 5 个气候因子, 均为 1960s—2010s 的均值, 初始分辨率为 1000 m。

(2) 地形因子的 DEM 数据(‘NASA/NASADEM\_HGT/001’)来源于谷歌地球引擎(Google earth engine, GEE), 初始分辨率为 30 m。地形衍生因子则由 ArcMap 10.8 计算获取, 共计算获取了 14 个地形因子。

(3) 生物因子变量来源一是从 GEE 平台获取的 Sentinel-2 影像各波段, 其时间范围设置为与采样时间一致(2023—2024 年), 并对各波段进行了中值合成; 来源二是从国家青藏高原科学数据中心(<https://data.tpdc.ac.cn/>)收集的 5 个生态生产力指数(2000s—2010s 均值)。

(4) 土壤因子使用历史土壤表层属性数据, 来源于“中国高分辨率国家土壤信息网格基本属性数据集”<sup>[16,27]</sup>和“用于陆面模拟的中国土壤数据集(第二版)”<sup>[28]</sup>。即使无法确定黏粒的运移深度, 土壤表层属性有很大概率会因为淋溶淀积过程而发生相应的变化。比如, 这个过程通常是在酸性条件下进行的<sup>[29]</sup>, 黏粒的减少可能导致表层土壤的砂化<sup>[30]</sup>。

(5) 环境协变量空间分辨率统一。本研究共有 71 个环境协变量, 使用双线性插值法将所有的协变量重采样至 90 m, 再进行空间预测建模和制图。

表 1 环境协变量的基本信息

Table 1 Basic information of environmental covariates

环境协变量	分辨率/ m	简称	来源
Environmental covariate	Resolution	Abbreviation	Source
气候 年平均降雨量 Mean annual precipitation	30	MAP	高分辨率山地环境制图

土壤学报  
Acta Pedologica Sinica

Climate	月平均最大降雨量 Mean monthly precipitation maximum	30	MMPmax	Fine resolution mapping of mountain environment
	月平均最小降雨量 Mean monthly precipitation minimum	30	MMPmin	
	降雨侵蚀力 Rainfall erosivity	30	RE	
	年平均干燥度 Mean annual aridity index	30	MAAI	
	月平均最大干燥度 Mean monthly aridity index maximum	30	MMAImax	
	月平均最小干燥度 Mean monthly aridity index minimum	30	MMAImin	
	年平均风速 Mean annual wind speed	30	MAWS	
	月平均最大风速 Mean monthly wind speed maximum	30	MMWSmax	
	月平均最小风速 Mean monthly wind speed minimum	30	MMWSmin	
	年平均日较差 Mean annual temperature daily range	30	MATDR	
	月平均最大日较差 Mean monthly temperature daily range maximum	30	MMTDRmax	
	月平均最小日较差 Mean monthly temperature daily range minimum	30	MMTDRmin	
	气温年较差 Annual temperature range	30	ATR	
	年平均气温 Mean annual temperature	30	MAT	
	年平均气温最大值 Mean annual temperature maximum	30	MATmax	
	年平均气温最小值 Mean annual temperature minimum	30	MATmin	
	月平均最高气温 Mean monthly temperature maximum	30	MMTmax	
	月平均最低气温 Mean monthly temperature minimum	30	MMTmin	
	月最低气温最大值 Lowest monthly temperature maximum	30	LMTmax	
	月最低气温最小值 Lowest monthly temperature minimum	30	LMTmin	
	月最高气温最大值 Highest monthly temperature maximum	30	HMTmax	
	月最高气温最小值 Highest monthly temperature minimum	30	HMTmin	
	年平均蒸发量 Mean annual evaporation	1000	MAE	
	年平均日照时数 Mean annual sunshine duration	1000	MASD	资源环境科学数据平台
	年平均相对湿度 Mean annual relative humidity	1000	MARH	Resource and environmental science data platform
	年平均气压 Mean annual atmospheric pressure	1000	MAAP	
	年平均地温 Mean annual ground temperature	1000	MAGT	
	高程 Elevation	30	Elevation	
	坡度 Slope	30	Slope	
	坡向 Aspect	30	Aspect	
	山体阴影 Hillshade	30	Hillshade	
	平面曲率 Plan curvature	30	PLC	
	剖面曲率 Profile curvature	30	PC	
地形	地形湿度指数 Topographic wetness index	30	TWI	谷歌地球引擎
Relief	地形起伏度 Relief amplitude	30	RA	Google earth engine
	地形粗糙度 Terrain roughness	30	TR	
	地形耐用指数 Terrain ruggedness index	30	TRI	
	地形位置指数 Topographic position index	30	TPI	
	地表切割深度 Surface incision depth	30	SID	
	河流强度指数 Stream power index	30	SPI	
	高程变异系数 Elevation coefficient of variation	30	ECV	
生物	Sentinel-2 影像波段: Band 1~12	10-60	S2_B1~S2_B12	谷歌地球引擎

Organisms			Google earth engine
归一化植被指数 Normalized difference vegetation index	30	NDVI	
增强植被指数 Enhanced vegetation index	500	EVI	国家青藏高原科学数据中心
植被覆盖度 Fractional vegetation cover	250	FVC	National Tibetan Plateau data center
净初级生产力 Net primary productivity	500	NPP	
总初级生产力 Gross primary productivity	500	GPP	
土壤厚度 Soil thickness	250	ST	
土壤有机碳 soil organic carbon	250	SOC	
土壤有机碳密度 soil organic carbon density	250	SOCD	
粉粒含量 Silt	250	Silt	
砂粒含量 Sand	250	Sand	
土壤 黏粒含量 Clay	250	Clay	Liu et al. <sup>[16,27]</sup>
Soil 容重 Bulk density	250	BD	
酸碱度 Acidity and alkalinity	250	pH	
阳离子交换量 Cation exchange capacity	250	CEC	
粗碎屑含量 Coarse fragment content	250	CF	
碎块岩石含量 Rock fragment content	90	Gravel	
孔隙度 Porosity	90	Porosity	Shi et al. <sup>[28]</sup>

#### 1.4 特征因子筛选

本研究使用 IBM Statistics SPSS 19.0 软件进行环境协变量的相关性分析，并剔除不显著相关的变量 ( $P < 0.01$ )。

Boruta 是一种基于 RF 的特征选择方法，通过随机地构建一些“影子特征”，然后比较真实特征和这些“影子特征”的重要性来确定最具代表性的特征子集。实现过程主要包含以下几步：（1）构建 RF 模型并计算各特征重要性；（2）创建与原始特征数量相同的“影子特征”，用于与真实特征比较；（3）根据特征重要性的比较结果划定重要特征和不重要特征；（4）多轮迭代，使用上一轮的重要特征和“影子特征”构建新的 RF 模型，计算本轮的特征重要性并更新重要特征的集合，直至重要特征集合不再有显著变化。此过程使用 r 语言的 Boruta 包<sup>[31]</sup>来实现，将所有确定的重要特征均作为建模输入。

#### 1.5 空间预测建模和模型性能评估

空间预测建模使用 QRF 模型，这是由 Meinshausen<sup>[32]</sup>提出的算法。本研究的模型调优考虑了 3 个重要参数，分别是决策树在分裂节点时考虑的特征数 (mtry)，每个节点在分裂前必须包含的最小样本数 (nodesize) 和决策树的数量 (ntree)。有研究表明，ntree 设置为默认值 500 通常足以产生稳定的预测<sup>[13,16]</sup>，故使用此参数设置。调优网格设置为 mtry 从 1 至最大的特征数量，步长为 1；nodesize 从 3 至 10，步长为 1。在最优参数下，建立空间预测模型。此过程使用 r 语言的 ranger 包<sup>[33]</sup>来实现。

考虑到本研究的样点数量有限，采用 10 折交叉验证对模型性能进行评估。将模型重复进行 50 次 10 折交叉验证，取精度评价指标的均值作为模型评估的最终结果<sup>[12]</sup>。共选取了决定系数 (coefficient of determination,  $R^2$ )，均方根误差 (Root mean square error, RMSE)，平均绝对误差 (Mean absolute error, MAE) 和预测区间覆盖概率 (Prediction interval coverage percentage, PICP) 4 个评价指标。10 折交叉验证使用 r 语言的 caret 包<sup>[34]</sup>来实现。

#### 1.6 不确定性评估和模型可解释性

使用 QRF 模型预测整个区域的 0.05、0.50 (中位数) 和 0.95 分位数的土壤黏化层厚度。然后，使用 0.05 和 0.95 分位数的值作差，求差值与中位数的比值，以此得到预测结果的不确定性指数<sup>[13]</sup>。

为确定在预测过程中最具影响力的环境变量,使用 r 语言的 dplyr 包<sup>[35]</sup>对特征重要性进行排序。此外,为进一步探明环境变量与黏化层厚度之间的关系,还使用 r 语言的 ALEPlot 包<sup>[36]</sup>生成了累积局部效应 (Accumulated local effects, ALE) 图来可视化每个预测变量如何影响黏化层厚度的预测。

## 2 结果

### 2.1 黏化层厚度的描述性统计特征

土壤样点的黏化层厚度范围为 7~138 cm, 平均厚度为 53.77 cm, 中位数为 47 cm, 标准差为 28.92 cm。偏度系数为 0.70 (>0.5), 表明数据分布存在轻微的正偏; 峰度系数为-0.18 (<0), 表明数据分布的峰值相较于正态分布更为平坦; 变异系数为 54%, 表明有较高的空间变异性。本研究使用原始的土壤分层厚度数据进行空间建模, 未经过数学变换。

### 2.2 黏化层厚度的影响因子筛选

从土壤黏化层厚度与环境协变量之间的 Pearson 相关系数 (图 2) 可以观察到黏化层厚度与一系列环境协变量之间呈负相关性 ( $P < 0.01$ ), 分别为 SOCD、SOC、MARH、MMPmin、Porosity、ATR、CEC、EVI、NDVI 和 MAP, 相关性从-0.17~-0.39; 此外, 黏化层厚度与 ST、MMAImax、MAE、MATmax、HMTmax、MMAImin、MAT、MMTmax、MAGT、MATmin、MMTmin、HMTmin、LMTmin、LMTmax、MASD、MAAI、BD、pH、S2\_B3、S2\_B2、S2\_B4、S2\_B5、S2\_B6、S2\_B12、S2\_B1 和 S2\_B7 之间呈正相关关系 ( $P < 0.01$ ), 相关性从 0.16~0.45。总体而言, 相关系数绝对值均不高 ( $|r| < 0.50$ )。使用这些协变量执行 Boruta 算法以进一步优化特征选择。




图 2 土壤黏化层厚度与环境协变量之间的 Pearson 相关系数

Fig. 2 Pearson correlation coefficients ( $r$ ) between soil argillic horizon thickness and environmental covariates ( $P < 0.01$ )

根据 Boruta 算法的优化筛选结果 (图 3), 将所有的重要特征作为黏化层厚度预测的建模输入。在土壤因子方面, 包括 ST、SOC、SOCD、Porosity 和 pH 共 5 个特征变量; 在气候因子方面, 包括 LMTmin、MATmin、ATR、MMTmin、HMTmin、MAGT、MATmax、MAT、MMAImax、MMAImin、MAAI、MAE、HMTmax 和 LMTmax 共 14 个特征变量。地形因子和生物因子未被纳入重要特征的集合, 说明地形因子和生物因子的重要性排序较低, 在预测中未起到决定性作用。

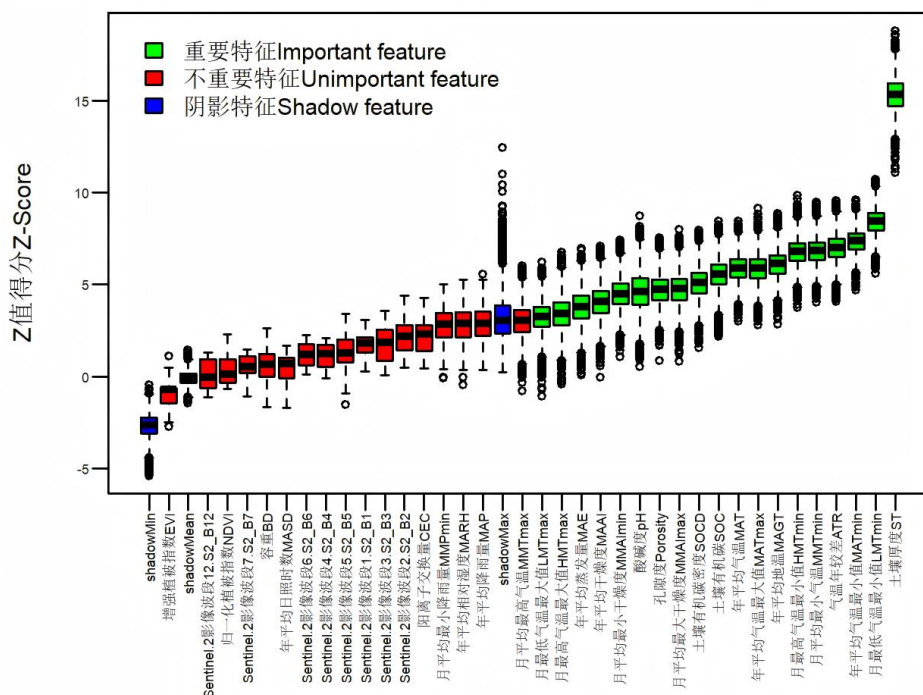


图 3 基于 Boruta 算法的环境协变量优化筛选 (以彩图发表)

Fig. 3 Optimized selection of environmental covariates based on the Boruta algorithm

### 2.3 模型预测性能

在 50 次迭代中, 模型性能的最终结果显示,  $R^2$ 、RMSE 和 MAE 的均值分别为 0.32、24.34 cm 和 19.47 cm, 表明此模型约解释了 32% 的土壤黏化层厚度的空间变化, 远优于 Howell 等<sup>[7]</sup>在美国莫哈韦沙漠地区预测中报道的结果 ( $R^2$  仅 0.11)。与类似的土壤 (或土层) 厚度 (或深度) 预测研究作对比 (在区域尺度上,  $R^2$  范围为 0.16~0.33<sup>[11-12,37-39]</sup>; 在国家尺度上,  $R^2$  范围为 0.11~0.41<sup>[40-42]</sup>), 本研究的预测性能优于绝大部分已报道的预测制图结果, 能较好地表征土壤黏化层厚度的空间变化特征。此外, 根据 Globalsoilmap 的技术规程, 如果不确定性被合理地估算, PICP 应非常接近预定义的 90% 预测区间。本研究的 PICP 均值为 86.2%, 非常接近 90%, 表明不确定性估计在非观测位置上也很大程度可靠。

### 2.4 预测制图及不确定性评估

研究区的土壤黏化层厚度预测结果如图 4 所示。结果显示, QRF 模型预测的均值图和中值图呈现出非常相似的空间分布格局。研究区的西部和西南部黏化层最厚, 厚度普遍在 80 cm 以上, 部分区域的厚度在 100~125 cm 之间; 而研究区的北部、东部和东南部黏化层较薄, 厚度普遍在 20~35 cm 之间, 部分区域的厚度小于 20 cm; 空间上整体沿西南—东北方向呈递减趋势。

0.05 和 0.95 分位数作为预测区间的上下限清楚地显示了黏化层厚度预测的不确定性。它们呈现出显然不同的空间结构, 其原因可能如下: 首先, 90% PI 本身就是一个非常大的预测区间, 多数研究给出的 90% PI 均存在较宽的范围<sup>[12,14,16,27]</sup>; 其次, 用来空间建模的黏化层厚度数据集的变异系数高达 54%, 表明预测变量自身的波动性较大, 可能导致预测区间的宽度也会相应增加; 最后, 黏化层厚度预测图未展现出非常高的模型性能, 这可能也是区间较宽的关键因素。

尽管如此, 86.2% 的 PICP 均值表明不确定性评估有效且非常可靠。使用 90% PI 与 0.50 分位数的比值绘制不确定性图 (图 5)。结果表明, 高不确定性 (深蓝色) 主要分布在山区丘陵地带。这些地区海拔高且交通不便, 实地调查采样的成本较高, 因此布设了较少的土壤剖面样点, 甚至可能没有样点覆盖。在东北平原 (松嫩平原、三江平原和辽河平原) 以及一些低地、低丘陵地区, 这些区域可达性良好, 布设的土壤调查点密度较高, 因此不确定性总体较低 (灰白色)。

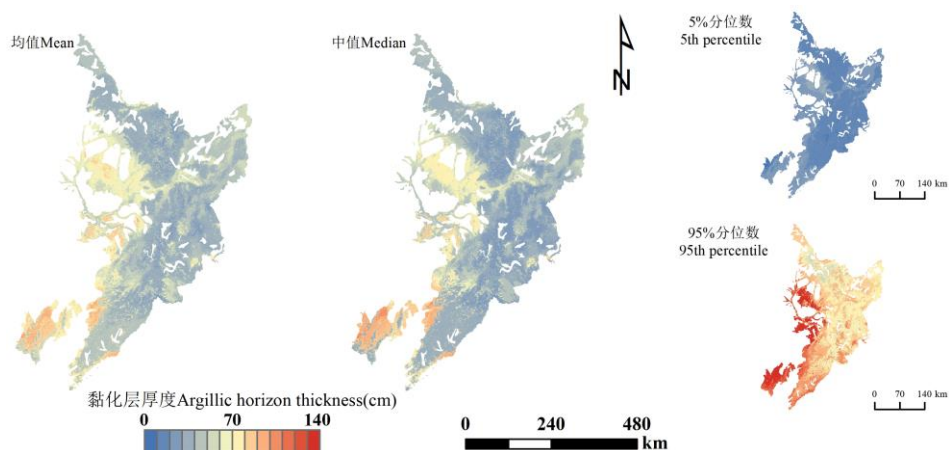


图 4 QRF 模型预测的土壤黏化层厚度, 包括均值、中值、低估界限和高估界限 (以彩图发表)

Fig. 4 The predicted soil argillic horizon thickness by the QRF model, including mean values, median values, lower limits, and upper limits




图 5 研究区土壤黏化层厚度的不确定性图 (以彩图发表)

Fig. 5 Uncertainty map of soil argillic horizon thickness in the study area

## 2.5 特征重要性和累积局部效应

**2.5.1 特征重要性** 图 6 展示了所有环境协变量的重要性排序结果。结果表明, ST 是建模过程中最重要的协变量, 随后依次是 pH、LMTmin、MATmin 和 ATR; MAT、LMTmax、HMTmax、MMTmin 和 MATmax 的重要性排序处于最后 5 位; 剩余 9 个协变量的重要性大致相当。值得注意的是, QRF 模型展示出的特征重要性 (图 6) 与 Pearson 相关性分析结果 (图 2) 并不完全一致, 这说明黏化层厚度与协变量之间的关系是非线性的, 否则协变量的重要性排序和  $|r|$  的排序应高度一致。

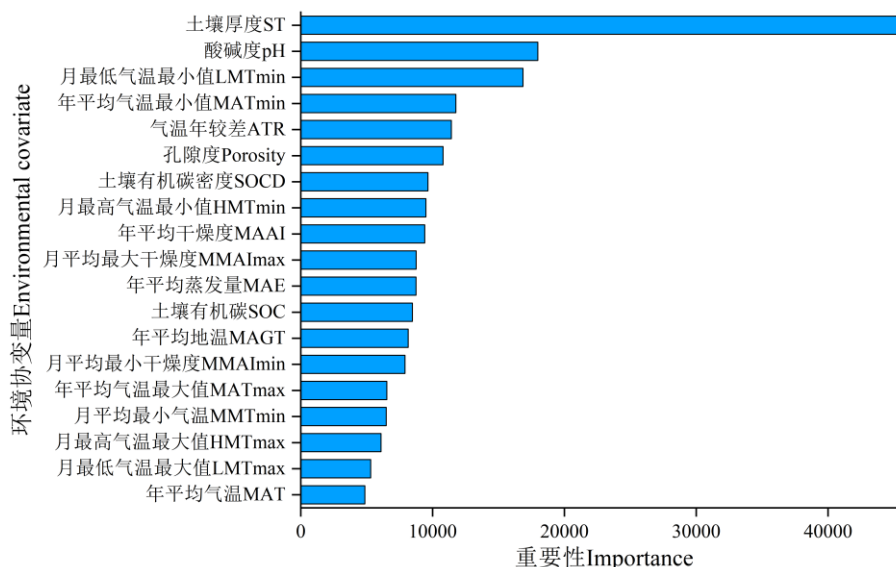
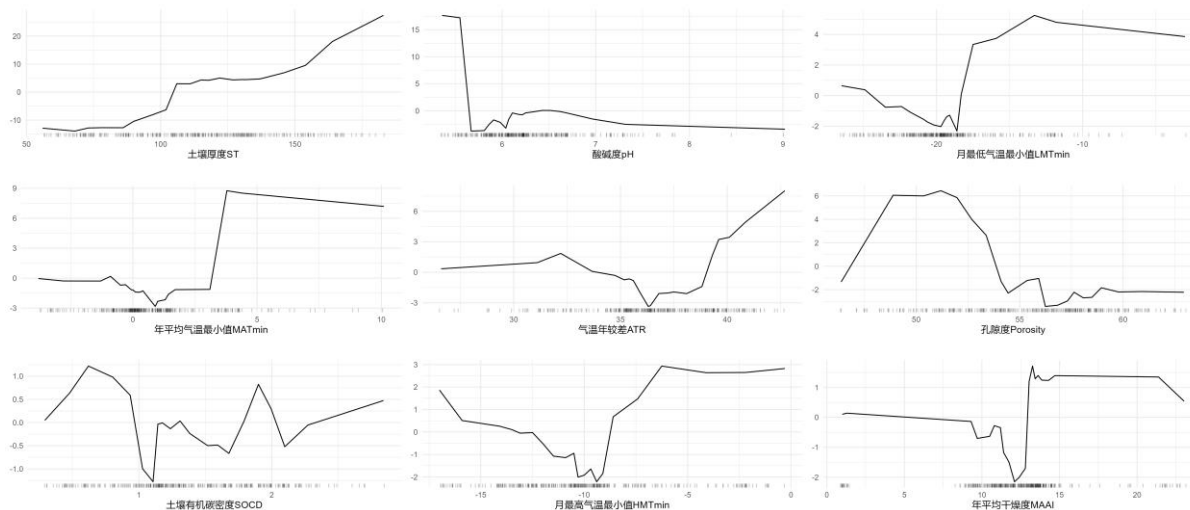


图 6 QRF 模型生成的环境协变量相对重要性排序

Fig. 6 The relative importance ranking of environmental covariates generated by the QRF model

**2.5.2 累积局部效应** 图 7 展示了前 9 个重要协变量的 ALE 图，证实了预测的黏化层厚度和环境协变量之间是非线性关系。结果显示，与黏化层厚度的平均预测值（即以零为中心）相比，较厚的土壤黏化层主要受高 ST 值、高 LMTmin 值、高 MATmin 值、高 ATR 值和高 MAAI 值的影响，反之亦然。此外，在野外调查过程中，往往在酸性土壤中发现较厚的土壤黏化层，而在碱性土壤中黏化层通常较薄，ALE 图的结果也很大程度支持了这一观点。剩余几个协变量对预测变量的影响呈波动变化趋势，表明它们与黏化层厚度预测的关系更加复杂。



注：Y 轴均为黏化层厚度。Note: Y axes represent soil argillic horizon thickness.

图 7 前 9 个重要协变量的累积局部效应图

Fig. 7 ALE plots for the top 9 important covariates

### 3 讨论

#### 3.1 特征筛选及特征重要性

在特征选择上,本研究使用 Pearson 相关性分析结合 Boruta 算法进行了双重筛选,从而识别出在制图过程中占主导作用的变量。Pearson 相关性分析的结果显示(图 2),所有地形协变量均被排除在外( $P < 0.01$ ),表明在景观复杂的大尺度平原区域,地形因子对于土壤属性预测的贡献较小,这一发现与前人在类似地貌区的数字制图经验基本一致<sup>[18-20]</sup>。地形因子在土壤的发育过程中并不提供任何物质和能量<sup>[30]</sup>,只是改变了气候、生物和母质提供的物质与能量的再分配。

在 Boruta 算法的优化筛选过程中(图 3),ST(土壤厚度)、LMTmin(月最低气温最小值)、MATmin(年平均气温最小值)和 ATR(气温年较差)是最重要的环境协变量。其中,ST 反映了土壤因子的影响,它与黏化层厚度之间的关系可以从两方面来解释。一是黏化层是 ST 的重要组成部分,它们之间存在着显著的正相关关系(图 2),这种关系可能与淋溶土的长期沉积和水文地质过程有关<sup>[5]</sup>。在 ST 较大的地区,土壤剖面经历了更长时间的沉积过程,细颗粒物有更多的时间和空间向下迁移,从而在较深处容易形成较厚的黏化层;相反,ST 较薄时,土壤剖面中的空间就非常有限,黏化层的形成机会也相应较少。另一个原因是 ST 对水分的保持和渗透能力有着重要影响。ST 较大的地区通常具有更好的水分保持能力<sup>[43]</sup>,能够为黏化层的形成提供稳定的水分条件。LMTmin, MATmin 和 ATR 是气候变量,它们对黏化层的影响主要体现在温度条件对土壤水分的调控作用上。在相同的温度条件下,浅层土壤的热变化较快,而深层土壤的热变化相对较慢,这就导致了不同位置、不同厚度的黏化层中水分蒸发和蒸腾速率的空间差异。其中,LMTmin 和 MATmin 主要体现的是低温对土壤环境的影响。ATR 则表示温度的季节性变化幅度,季节性的温度变化会导致周期性的土壤水分变化。

此外,在 Boruta 算法中,重要性排序最低的变量几乎均来自生物协变量。这是因为生物协变量的测量和统一量化通常较其他环境因子更为困难。常见的做法是采用遥感波段或一些植被指数作为替代指标来间接反映生物因子的影响<sup>[10,26]</sup>。但中国东北地区作为国家的粮食主产区,高强度的人为管理活动以及大量的资金投入显著地改变了农业生产的条件。虽然土壤黏化层的存在构成了生产力的一个潜在障碍,但得益于这些干预措施,作物的长势和产量仍能得到一定程度的提升,使得生物变量的空间分布格局呈现出趋同态势。因此,生物协变量也不能较好地反映黏化层的空间分异特征。

最后,值得注意的是,QRF 模型展示出的特征重要性(图 6)与 Boruta 算法得出的特征排序结果(图 3)并不完全吻合,这种差异可能源于两种模型的算法原理不同。虽然 QRF 模型和 Boruta 算法均建立在 RF 的基础上<sup>[31-32]</sup>,但 QRF 模型输出的特征重要性反映的是特征变量对预测变量的直接影响,而 Boruta 算法通过与“影子特征”比较来确定特征重要性,这体现的是一种间接关联。但无论是哪种方法,ST 始终是预测过程中最重要的协变量。因此,在未来的土壤黏化层厚度制图研究中,可以考虑将 ST 作为一个关键的输入变量。

### 3.2 土壤黏化层厚度制图的可实现性、局限性和发展前景

本研究主要证明了土壤黏化层厚度预测制图的可实现性,哪怕是在大面积的景观复杂地区且仅有稀疏有限的土壤样本点的情况大。以往的数字制图研究<sup>[11-14,16]</sup>普遍认为地形和生物因子对土壤(或土层)厚度的空间分布具有显著影响,然而本研究的结果表明气候和土壤因子在制图过程中起到关键作用。这一差异的原因主要在于前人研究多聚焦于地形异质性较强的区域,而在景观复杂的大尺度平原区域尚无深入探讨。本研究中,将大量气候数据与历史土壤表层数据作为环境协变量,用以表征土壤的淋溶淀积过程并进行空间制图,是一种切实可行的方法。但是,气候变量是近 30 年或近 60 年的数据,土壤因子变量是近 10 年或近 40 年的数据。黏化层的发育是一个长期而复杂的过程,往往需要至少 2000 年的时间,在某些地区可能甚至需要 10 000 年以上<sup>[44]</sup>。因此,本研究的主要局限性在于无法准确量化其成土过程中长时间序列的环境条件变化。未来的研究应开发新的环境变量以更好地表征黏化层的空间变化。例如,黏化层的黏粒大部分来源于母质<sup>[30,45]</sup>,氧化铁的含量<sup>[46]</sup>也在一定程度上反映了成土年龄。有效表征母质和氧化铁的含量并将其作为协变量输入模型可能是未来提高制图精度的发展方向之一。

此外, 土壤(或土层)厚度这一属性的空间预测具有显著的尺度效应<sup>[12,47]</sup>, 在区域和国家尺度上它的预测精度普遍欠佳( $R^2 < 0.5$ ), 但在全球尺度上其预测精度尚可。土壤(或土层)厚度受局部地质条件的显著影响而具有高度的空间异质性, 现有的技术手段难以精准捕捉这种异质性特征, 因此增大样本量也是提升预测精度的必要途径之一, 但样本量的增加往往伴随着采样成本的大幅上升, 如何在采样成本和预测精度之间找到平衡点是一个亟待解决的问题。最后, 需要注意的是, 与黏化层厚度一样, 黏化层出现的上界及其紧实度也是影响植物根系下扎、水分和养分向下运移以及农业生产上深耕深松难度的两个因素, 这两个因素的空间预测应是下一步研究需考虑的对象。

## 4 结论

本研究基于稀疏的土壤样本点, 在大面积的景观复杂地区, 将 QRF 模型与一组丰富的环境协变量相结合, 实现了土壤黏化层厚度的空间预测制图。50 次重复 10 折交叉验证的平均  $R^2$  为 0.32, 此结果优于大多数土壤(或土层)厚度(或深度)的历史预测研究在区域或国家尺度上所报道的精度( $R^2$  为 0.11~0.41)。PICP 的均值为 86.2%, 非常接近预定义的 90%, 表明 QRF 产生的预测不确定性估计是有效且可靠的。最终预测结果显示, 研究区的西部和西南部黏化层最厚, 厚度普遍在 80 cm 以上, 部分区域的厚度在 100~125 cm 之间; 研究区的北部、东部和东南部黏化层较薄, 厚度普遍在 20~35 cm 之间, 部分区域的厚度小于 20 cm。这些空间分布格局的揭示能够为土壤分区管理政策的制定提供可靠的依据。在制图过程中, 本研究证明了将土壤厚度作为建模输入的必要性, 还发现土壤变量和气候变量的重要性普遍高于生物变量和地形变量。这些发现将为类似大尺度的土层厚度预测制图研究提供重要参考。

## 参考文献 (References)

- [1] Bockheim J G, Gennadiyev A N. The role of soil-forming processes in the definition of taxa in Soil Taxonomy and the World Soil Reference Base[J]. Geoderma, 2000, 95(1): 53-72.
- [2] Weil R, Brady N. The nature and properties of soils[M]. New York, USA: Pearson International, 2016.
- [3] Soil Survey Staff. Keys to Soil Taxonomy[M]. 13th ed. United States Department of Agriculture: Natural Resources Conservation Service, 2022.
- [4] Zhou J M, Shen R F. Dictionary of Soil Science[M]. Beijing: Science Press, 2016. [周健民, 沈仁芳. 土壤学大辞典[M]. 北京: 科学出版社, 2016.]
- [5] Turniški R, Zupančič N, Grčman H. Geochemical evidence of illuvial processes in clay-rich soils on limestones in a humid temperate climate[J]. Geoderma, 2023, 429: 116266.
- [6] Zhao Y S, Wang E H, Cruse R M, et al. Characterization of seasonal freeze-thaw and potential impacts on soil erosion in northeast China[J]. Canadian Journal of Soil Science., 2012, 92(3): 567-571.
- [7] Howell D, Kim Y, Haydu-Houdeshell C, et al. Chapter 34 fitting soil property spatial distribution models in the Mojave Desert for digital soil mapping[M]. Developments in Soil Science, 2006, 31: 465-624.
- [8] Dong F J, Zhang Z B, Jiang F H, et al. Spatial distribution of the buried depth and thickness of Albic soil Albic layer in Sanjiang Plain and its influencing factors[J]. Acta Pedologica Sinica, 2025, 62(2): 362-374. [董芳瑾, 张中彬, 蒋发辉, 等. 三江平原白浆土白浆层埋深与厚度空间分布格局及其驱动因素[J]. 土壤学报, 2025, 62(2): 362-374.]
- [9] McBratney A B, Mendonça Santos M L, Minasny B. On digital soil mapping[J]. Geoderma, 2003, 117(1/2): 3-52.
- [10] Chen S C, Arrouays D, Leatitia Mulder V, et al. Digital mapping of GlobalSoilMap soil properties at a broad scale: A review[J]. Geoderma, 2022, 409: 115567.
- [11] Dharumarajan S, Vasundhara R, Suputhra A, et al. Prediction of soil depth in Karnataka using digital soil mapping

- approach[J]. *Journal of the Indian Society of Remote Sensing*, 2020, 48(11): 1593-1600.
- [12] Chen S C, Richer-De-Forges A C, Leatitia Mulder V, et al. Digital mapping of the soil thickness of loess deposits over a calcareous bedrock in central France[J]. *Catena*, 2021, 198: 105062.
- [13] Liu F, Yang F, Zhao Y G, et al. Predicting soil depth in a large and complex area using machine learning and environmental correlations[J]. *Journal of Integrative Agriculture*, 2022, 21(8): 2422-2434.
- [14] Chen Y L, Liang T B, Zhang Y L, et al. Spatial prediction of soil thicknesses in Sichuan Province based on feature-ensemble learning[J]. *Soils*, 2023, 55(4): 894-902. [陈玉蓝, 梁太波, 张艳玲, 等. 基于特征集成学习的四川省土壤厚度预测[J]. *土壤*, 2023, 55(4): 894-902.]
- [15] Hengl T, Mendes De Jesus J, Heuvelink G B M, et al. SoilGrids250m: Global gridded soil information based on machine learning[J]. *PLoS One*, 2017, 12(2): e0169748.
- [16] Liu F, Wu H Y, Zhao Y G, et al. Mapping high resolution national soil information grids of China[J]. *Science Bulletin*, 2022, 67(3): 328-340.
- [17] Shangguan W, Hengl T, Mendes De Jesus J, et al. Mapping the global depth to bedrock for land surface modeling[J]. *Journal of Advances in Modeling Earth Systems*, 2017, 9(1): 65-88.
- [18] Huang P, Huang Q, Wang J T, et al. Predicting surface soil pH spatial distribution based on three machine learning methods: A case study of Heilongjiang Province[J]. *Environmental Monitoring and Assessment*, 2025, 197(4): 367.
- [19] Bao Y L, Yao F M, Meng X T, et al. A fine digital soil mapping by integrating remote sensing-based process model and deep learning method in Northeast China[J]. *Soil and Tillage Research*, 2024, 238: 106010.
- [20] Luo C, Zhang W Q, Meng X T, et al. Mapping the soil organic matter content in Northeast China considering the difference between dry lands and paddy fields[J]. *Soil and Tillage Research*, 2024, 244: 106270.
- [21] Shi X Z, Yu D S, Warner E D, et al. Soil database of 1:1,000,000 digital soil survey and reference system of the Chinese genetic soil classification system[J]. *Soil Horizons*, 2004, 45(4): 129.
- [22] Chinese Soil Taxonomy Research Group, Institute of Soil Science, Chinese Academy of Sciences, Cooperative Research Group on Chinese Soil Taxonomy. *Keys to Chinese Soil Taxonomy*[M]. 3rd ed. Hefei: Press of University of Science and Technology of China, 2001. [中国科学院南京土壤研究所土壤系统分类课题组, 中国土壤系统分类课题研究协作组. *中国土壤系统分类检索(第三版)*. 合肥: 中国科学技术大学出版社, 2001.]
- [23] Zhai R C, Xin G, Zhang Z Y. *Soil series of China: Heilongjiang volume*[M]. Beijing: Science Press, 2020. [翟瑞常, 辛刚, 张之一. *中国土系志: 黑龙江卷*[M]. 北京: 科学出版社, 2020.]
- [24] Sui Y Y, Jiao X G, Li J W. *Soil series of China: Jilin volume*[M]. Beijing: Science Press, 2019. [隋跃宇, 焦晓光, 李建维. *中国土系志: 吉林卷*[M]. 北京: 科学出版社, 2019.]
- [25] Wang Q B, Han C L, Sun F J, et al. *Soil series of China: Liaoning volume*[M]. Beijing: Science Press, 2020. [王秋兵, 韩春兰, 孙福军, 等. *中国土系志: 辽宁卷*[M]. 北京: 科学出版社, 2020.]
- [26] Zhu A X, Yang L, Fan N Q, et al. The review and outlook of digital soil mapping[J]. *Progress in Geography*, 2018, 37(1): 66-78. [朱阿兴, 杨琳, 樊乃卿, 等. 数字土壤制图研究综述与展望[J]. *地理科学进展*, 2018, 37(1): 66-78.]
- [27] Liu F, Zhang G L, Song X D, et al. High-resolution and three-dimensional mapping of soil texture of China[J]. *Geoderma*, 2020, 361: 114061.
- [28] Shi G S, Sun W Y, Shangguan W, et al. A China dataset of soil properties for land surface modelling (version 2, CSDLv2)[J]. *Earth System Science Data*, 2025, 17(2): 517-543.
- [29] Ndzana G M, Huang L, Wang J B, et al. Characteristics of clay minerals in soil particles from an argillic horizon of Alfisol in central China[J]. *Applied Clay Science*, 2018, 151: 148-156.
- [30] Zhang L, Zhang F R, Li C, et al. Impact of soil erosion on argic horizon identification and Luvisols classification in the Loess Plateau[J]. *Chinese Journal of Soil Science*, 2021, 52(2): 261-268. [张蕾, 张凤荣, 李超, 等. 土壤侵蚀作用对黄土高原黏化层鉴定和淋溶土分类的影响[J]. *土壤通报*, 2021, 52(2): 261-268.]

- [31] Kursa M B, Rudnicki W R. Feature selection with the boruta package[J]. Journal of Statistical Software, 2010, 36(11): 1-13.
- [32] Meinshausen N. Quantile regression forests[J]. Journal of Machine Learning Research, 2006, 7: 983-999.
- [33] Wright M N, Wager S, Probst P. ranger: A fast implementation of random forests[Z].
- [34] Kuhn M, Wing J, Weston S, et al. caret: Classification and regression training[Z].
- [35] Wickham H, François R, Henry L, et al. dplyr: A grammar of data manipulation[Z].
- [36] Apley D. ALEPlot: Accumulated local effects (ALE) plots and partial dependence (PD) plots[Z].
- [37] Darren K, Mathew W, Brendan M, et al. Eighty-metre resolution 3D soil-attribute maps for Tasmania, Australia[J]. Soil Research, 2015, 53(8): 932-932.
- [38] Vaysse K, Lagacherie P. Evaluating digital soil mapping approaches for mapping GlobalSoilMap soil properties from legacy data in Languedoc-Roussillon (France)[J]. Geoderma Regional, 2015, 4: 20-30.
- [39] Zhang W T, Hu G Q, Sheng J D, et al. Estimating effective soil depth at regional scales: Legacy maps *versus* environmental covariates[J]. Journal of Plant Nutrition and Soil Science, 2018, 181(2): 167-176.
- [40] Mulder V L, Lacoste M, Richer-De-Forges A C, et al. GlobalSoilMap France: High-resolution spatial modelling the soils of France up to two meter depth[J]. Science of the Total Environment, 2016, 573: 1352-1369.
- [41] Lacoste M, Mulder V L, Richer-De-Forges A C, et al. Evaluating large-extent spatial modeling approaches: A case study for soil depth for France[J]. Geoderma Regional, 2016, 7(2): 137-152.
- [42] Guerrero E, Pérez A, Arroyo C, et al. Building a national framework for pedometric mapping: Soil depth as an example from Mexico[M]. Arrouays D, McKenzie N, Hempel J, et al., eds.//GlobalSoilMap. 2014: 103-108.
- [43] Luo Z B, Fan J, Shao M A, et al. Evaluating soil water dynamics and vegetation growth characteristics under different soil depths in semiarid loess areas[J]. Geoderma, 2024, 442: 116791.
- [44] Li J, Huang C M, Yang G L, et al. Pedogenesis of Argosol-like Paleosol formation in the late mesozoic Sichuan Basin[J]. Chinese Journal of Soil Science, 2022, 53(1): 1-11. [李军, 黄成敏, 杨国林, 等. 四川盆地晚中生代古淋溶土发生学特征与形成因素研究[J]. 土壤通报, 2022, 53(1): 1-11.]
- [45] Torrent J, Nettleton W D. A simple textural index for assessing chemical weathering in soils[J]. Soil Science Society of America Journal, 1979, 43(2): 373-377.
- [46] Levine E R, Ciolkosz E J. Soil development in till of various ages in northeastern Pennsylvania[J]. Quaternary Research, 1983, 19(1): 85-99.
- [47] Zhu Q L, Han Z, Fang F Y, et al. Soil thickness prediction models: Types, accuracy and influencing factors[J]. Catena, 2025, 258: 109282.

(责任编辑: 檀满枝)