doi:10.6041/j.issn.1000-1298.2025.11.063

基于高光谱协同的土壤重金属 Hg 含量空间预测

杨奇勇[1]　李文军[1]　肖　琼[2]　章　程[2]

(1. 邵阳学院农林生态学院, 邵阳 422000; 2. 中国地质科学院岩溶地质研究所, 桂林 541004)

摘要: 为实现基于高光谱分析的土壤重金属 Hg 含量准确预测,选取桂东北典型农业土壤为研究对象,在分析土壤重金属 Hg 含量与原始及其 8 种变换形式的土壤光谱反射率关系的基础上,遴选最佳变换方式高光谱特征波长作为辅助变量进行土壤重金属 Hg 含量空间预测的协同克里格(COK)分析。结果表明:研究区域土壤重金属 Hg 含量与 9 种土壤光谱反射率均具有显著相关性,对数微分变换的光谱反射率能更好地表征土壤光谱与土壤重金属 Hg 含量的关系特征;与普通克里格(OK)相比,COK 能提高模型稳健性,降低模型误差,随着协同变量增加,COK 模型稳健性和预测精度呈上升的趋势减弱;由 1 412、1 052、738 nm 构成的三变量 COK 模型为研究区域最佳 COK 模型,预测数据与验证数据间 R^2 由 OK 的 0.117 上升到 0.592,而 RMSE、MAE 分别由 OK 的 0.214、0.247 mg/kg 减少到 0.167、0.154 mg/kg。这说明容易获取的土壤光谱信息构成的 COK 模型,可成为土壤重金属含量空间预测的一种经济有效方法。

关键词: 土壤重金属; 空间预测; 高光谱; 协同克里格; 辅助变量

中图分类号: TP79; S151.3　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0651-07　　**OSID**:

Spatial Prediction of Soil Heavy Metal Hg Content Based on Hyperspectral Data as Covariates

YANG Qiyong[1]　LI Wenjun[1]　XIAO Qiong[2]　ZHANG Cheng[2]

(1. *Agriculture Forestry Ecology College*, *Shaoyang University*, *Shaoyang* 422000, *China*
2. *Institute of Karst Geology*, *Chinese Academy of Geological Sciences*, *Guilin* 541004, *China*)

Abstract: When the heavy metals content in the soil accumulates to a certain level, it not only hinders the healthy growth of living organisms, but also poses a potential threat to the stability of the ecosystem. In order to achieve rapid measurement of soil heavy metal Hg content based on coKriging (COK) with soil hyperspectral data as covariates, totally 368 soil samples at 0 ~ 20 cm depth were collected as research objects from Shazi Town in northeast of Guangxi Zhuang Autonomous Region. The raw hyperspectral reflectance (R) of soil samples was measured by the standard procedure with an ASD FieldSpec4 instrument, which was transformed to eight spectral indices, such as the first order differential reflectance (FDR), the second order differential reflectance (SDR), reciprocal of reflectance (RR), differential for reciprocal of reflectance (RDR), logarithm of reflectance (LR), differential for logarithm of reflectance (LDR), square root of reflectance (SQR), differential for square root of reflectance (SQDR). The relationship between the soil heavy metal Hg content and the raw hyperspectral reflectance and its eight transformation was analyzed, and the spectral characteristic bands of the optimal transformation method were selected as auxiliary variables for the coKriging (COK) analysis of spatial prediction. The results showed that the content of heavy metal Hg in the soil of study area had significant correlations with the reflectance of the nine types of soil spectra. The LDR can better represent the relationship characteristics between soil spectra and the content of heavy metal Hg in the soil. Compared with the ordinary Kriging method (OK), the COK method can not only enhance the robustness of the model but also reduce the error of the model. As the number of collaborative variables increased, the upward trend of the robustness and prediction accuracy of the COK model was weakened. The three-coefficient variable COK model composed of 1 412 nm, 1 052 nm and 738 nm was the optimal COK

收稿日期: 2025-06-14　修回日期: 2025-06-30

基金项目: 国家自然科学基金国际(地区)合作与交流项目(42261144672-1)

作者简介: 杨奇勇(1976—),男,研究员,博士,主要从事遥感应用与土壤数字制图研究,E-mail: yangqiyong0739@163.com

analysis model for the study area. The R^2 between the predicted data and the validation data was increased from 0.117 of the OK to 0.592 of COK, while the RMSE and MAE were decreased from 0.214 mg/kg and 0.247 mg/kg to 0.167 mg/kg and 0.154 mg/kg, respectively. This indicated that the COK model constructed based on easily obtainable soil spectral information can provide an economical and effective method for spatial prediction of soil heavy metal content.

Key words: soil heavy metal; spatial prediction; hyperspectral; coKriging; auxiliary variable

0 引言

重金属在土壤中具有生物积累性、间接危害性和不可生物降解性的特点。当土壤中的重金属含量积累达到一定程度时,不但不利于生物体的健康生长,还可能潜在地威胁生态系统的稳定性[1]。因此,预测区域土壤重金属含量、掌握其空间分布特征,无论是对土壤污染的风险监控,还是对污染土壤的治理与修复都具有重要的现实意义。

传统方法获取原位土壤重金属含量成本高、周期长、效率低,无法满足快速、大范围和长期的动态监测需求[2]。普通克里格(Ordinary Kriging, OK)法可给出土壤属性空间预测的最佳线性无偏估计量,但其预测精度受样品数量、地理环境等因素的影响[3-5]。因此,借助辅助变量提高土壤属性预测精度的研究引起了越来越多学者的关注[6-8]。随着光谱学兴起,具有测定简单、省时、无损等优点的高光谱数据,作为辅助变量助力于土壤重金属含量空间预测[9-11]。文献[12-13]均在揭示土壤重金属含量与土壤原始及其变换方式光谱反射率相关关系的基础上,遴选敏感波段建立土壤重金属含量反演模型。与传统的辅助变量相比,虽然利用土壤高光谱数据构建的土壤重金属含量反演模型提高了预测精度,但所采用的光谱变换方式单一,可能并不能完全揭示土壤高光谱信息与土壤属性间的耦合关系。

在众多的借助辅助变量提高土壤属性空间预测精度的方法中,协同克里格(CoKriging, COK)法能有效提高土壤属性的空间预测精度,应用较为广泛[1,14-16]。COK 法并不直接使用辅助变量预测土壤属性,而是将其作为协同变量来改善空间预测精度。有研究指出,利用辅助变量进行 COK 分析能大大提高土壤属性预测精度[15,17]。但也有研究表示,只有当辅助变量与土壤属性相关系数大于 0.5 时,COK 法才能显著提高土壤属性空间预测精度[18]。因此,如何优化光谱变换方法、选择典型波长作为辅助变量的系统性研究亟待开展[19]。本文以桂东北的沙子镇为研究区域开展研究,通过土壤重金属 Hg 含量与土壤原始光谱及其各种变换形式的光谱反射率的相关性对比,选取最佳土壤光谱变换方法、遴选显著性光谱波长作为辅助变量;进行基于“类回归”的土壤重金属 Hg 含量 COK 分析,通过模型对比与精度验证,确定研究区域土壤重金属 Hg 含量空间预测的最佳辅助变量组合与 COK 模型;绘制研究区域土壤重金属 Hg 含量空间分布图,为区域土壤重金属调查和生态农业建设提供科学参考。

1 材料与方法

1.1 研究区域与土壤样品采集

沙子镇位于桂东北(24°42′29.51″~24°54′0.51″N,110°37′41.82″~110°49′19.82″E),总面积为 193 km^2(图 1)。该镇属亚热带季风气候,年均气温 20.3℃,年均降水量 1 355~1 865 mm。海拔在 27~795 m 之间,属于典型的岩溶地貌区。成土母质以石灰岩为主,土壤类型有石灰(岩)土、粗骨土、水稻土、紫色土和红壤。沙子镇是“广西淮山之乡”、四季“水果之乡”“绿色水果基地”。加大沙子镇土壤质量监控与保护,是其生态农业可持续发展的保证。

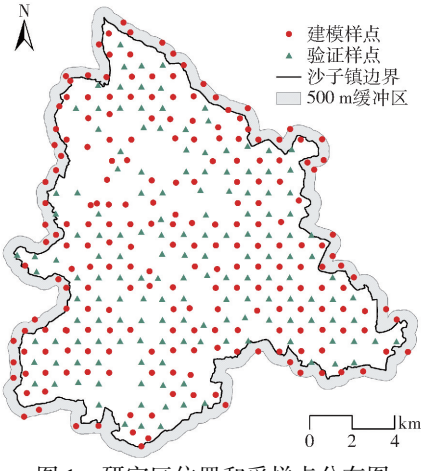


图 1 研究区位置和采样点分布图

Fig. 1 Location of study area and sampling points

在 ArcGIS 10.8 中,以沙子镇为界建立 500 m 缓冲区,再进行 2 个 1 km×1 km 网格嵌套布点。利用网格坐标进行土壤野外调查导航,当采样点位于水域、道路、房屋或难以到达的位置时,在 100 m 范围内进行调整,舍去无法调整的样点。采样时间为 2020 年 7—8 月,在 1 m^2 范围内采集 3 个 0~20 cm 土壤样品,同时记录采样点位置的经纬度、海拔以及周围环境特征,共获得土壤重金属 Hg 含量有效样点 368 个(图 1)。

1.2　土壤重金属 Hg 含量测定与样品划分

土壤样品带回实验室，自然风干后分成 2 部分。一部分土壤样品磨碎过 100 目筛，采用 HNO_3 - HCl - HF - $HClO_4$ 法电热板加热消解并处理后，用原子荧光法测定 Hg 含量。将缓冲区内的所有样点和沙子镇范围内的一个 1 km × 1 km 网格样点作为建模数据，沙子镇范围内的另一个网格样点作为模型预测精度的验证数据（图 1，表 1）。另一部分土壤样品磨碎过 10 目筛，用于高光谱数据采集。

表 1　沙子镇土壤重金属 Hg 含量统计特征

Tab. 1　Statistical characteristics of heavy metal Hg in soil in Shazi Town

参数	建模数据集	验证数据集
样品数量/个	214	154
平均值/(mg·kg^{-1})	0.35	0.35
最小值/(mg·kg^{-1})	0.07	0.04
最大值/(mg·kg^{-1})	1.30	1.30
标准差/(mg·kg^{-1})	0.26	0.25
变异系数/%	74.29	71.43
偏度	2.03	2.01
峰度	7.17	7.64

1.3　土壤光谱测定与光谱转换

采用 ASD FieldSpec 4 型地物波谱仪在黑室内进行土壤光谱测量。测量中取 3 次光谱测量均值作为土壤样品的反射光谱数据。每个样品去除噪声较大边缘波段，只保留波段 400 ~ 2 400 nm 用于后续分析[6]。图 2 为建模样品土壤原始光谱曲线。

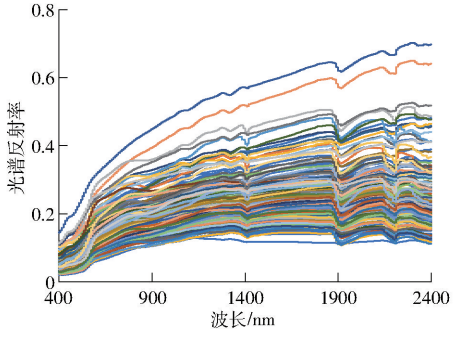


图 2　土壤原始光谱反射率

Fig. 2　Curves of raw spectral reflectance

分别对土壤原始光谱反射率（Raw hyperspectral reflectance，R）进行一阶微分（First order differential reflectance，FDR）、二阶微分（Second order differential reflectance，SDR）、倒数（Reciprocal of reflectance，RR）、倒数微分（Differential for reciprocal of reflectance，RDR）、对数（Logarithm of reflectance，LR）、对数微分（Differential for logarithm of reflectance，LDR）、平方根（Square root of reflectance，SQR）、平方根微分（Differential for square root of reflectance，SQDR）等变换。利用 9 种反射率指标进行后续分析。

1.4　研究方法

1.4.1　辅助变量选取

辅助变量选取直接决定模型精度。选取辅助变量主要步骤为：①进行土壤重金属 Hg 含量与 9 种光谱反射率指标相关性分析，设定相关系数（r）绝对值（$|r|$）阈值作为敏感波长选取标准，分析确定最佳变换方式光谱反射率指标。②绘制最佳光谱反射率指标变化曲线图，进行波长与土壤重金属 Hg 含量相关性的显著性检验。③针对通过显著性检验的波长，选取局部正相关系数极大值的波长和局部负相关系数极小值的波长作为最优特征波长集合。④用方差膨胀因子（Variance inflation factor，VIF）对选取的最优特征波长集合进行筛选，利用 t 检验（t 为回归系数与标准差比值）对筛选出的波长进行显著性检验，通过检验的波长作为候选辅助变量进行 COK 分析。

1.4.2　协同克里格分析

地统计分析方法与原理参考文献[20 - 21]。选取决定系数（R^2）、均方根误差（RMSE）和平均绝对误差（MAE）[22] 3 个指标，分别对预测模型性能和模型预测精度进行评价。在 ArcGIS 10.8 中采用“类回归”方法进行 COK 分析，主要步骤包括：①单变量 COK 分析：依次将每一个候选辅助变量作为协同变量进行土壤重金属 Hg 含量 COK 分析，并对各模型性能进行排序；其中 R^2 最大、RMSE 和 MAE 最小的模型最优，定义为 COK1；如果 COK1 模型优于 OK 模型，则进行步骤②。②双变量 COK 分析：在 COK1 模型基础上，依次加入其他候选辅助变量进行 COK 分析，并对各模型性能进行排序，最优模型定义为 COK2；如果 COK2 模型优于 COK1 模型，则进行步骤③。③三变量 COK 分析：将其他候选辅助变量依次加入 COK2 模型中进行 COK 分析，通过对各个模型性能进行排序，确定最优 COK3 模型。④土壤重金属 Hg 含量空间预测：利用预留的验证数据对上述最优模型的土壤重金属 Hg 含量空间预测精度进行验证；绘制土壤重金属 Hg 含量空间分布专题图，分析其空间分布特征。

2　结果与分析

2.1　协同克里格分析辅助变量选取

2.1.1　最优光谱变换及特征波长确定

参考 YATES 等[18] 的研究成果，选取 $|r| > 0.5$ 的波长作为敏感波长，并对 9 种光谱反射率与土壤

重金属 Hg 含量的相关系数进行最大值、最小值和平均值统计分析(表 2)。从表 2 可以看出,土壤重金属 Hg 含量与 9 种光谱反射率均具有显著相关性,各光谱反射率的 $|r|$ 最大值为 0.262 ~ 0.743;无论是建模数据还是验证数据,$|r|$ 最大值均出现在 LDR 中,且两个数据集的敏感波段数量均最多,达到 130。说明通过对原始光谱反射率进行对数微分变换后有效地突出了光谱曲线峰谷,能更好地表征土壤光谱与土壤重金属 Hg 含量的关系特征,因此,LDR 为最佳光谱变换方式。研究中建模数据共 214 个,因此 $|r| > 0.167$($p < 0.01$)的波长才可作为特征波长。利用局部极大值法,共选出 83 个特征波长(图 3),其中有 9 个特征波长相关系数绝对值大于 0.5。

表 2 土壤重金属 Hg 含量与原始及其变换形式后的光谱反射率相关系数统计分析

Tab. 2 Statistical analysis of correlation coefficient between content of heavy metal Hg in soil and raw spectral reflectance and its transformation

光谱反射率	建模数据				验证数据			
	最大值	最小值	平均值	敏感波段数	最大值	最小值	平均值	敏感波段数
R	-0.033	-0.330	-0.115	0	-0.080	-0.344	-0.162	0
FDR	0.549	-0.611	-0.017	110	0.610	-0.704	-0.053	110
SDR	0.602	-0.553	-0.012	38	0.706	-0.645	-0.011	38
RR	0.305	-0.028	0.072	0	0.281	0.035	0.124	0
RDR	0.607	-0.517	-0.061	30	0.712	-0.642	0.009	30
LR	-0.002	-0.334	-0.096	0	-0.072	-0.344	-0.163	0
LDR	0.625	-0.637	0.049	130	0.720	-0.743	-0.020	130
SQR	-0.058	-0.269	-0.110	0	0.007	-0.262	-0.023	0
SQDR	0.428	-0.387	-0.006	0	0.274	-0.235	0.013	0

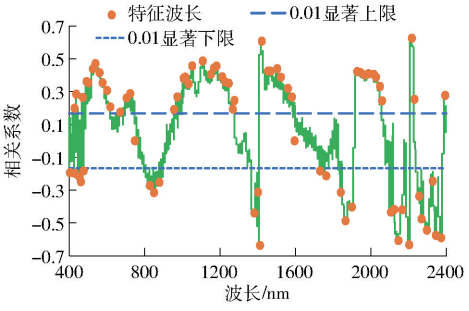


图 3 特征波长在土壤重金属 Hg 含量与 LDR 光谱反射率相关系数图上的分布

Fig. 3 Distribution of sensitive wavelengths on curve of correlation coefficient between heavy metal Hg in soil and spectral reflectance of LDR

2.1.2 候选辅助变量确定

以土壤重金属 Hg 含量为自变量,各特征波长为因变量在 ArcGIS 中进行偏最小二乘回归(OLS)分析,剔除 VIF 大于等于 7.5 的最大特征波长[23];再利用剩余的特征波长进行 OLS 分析,再剔除 VIF 大于等于 7.5 的最大特征波长,直到所有剩余特征波长的 VIF 小于 7.5。选取 $t > 2.0$($|t| > t_\alpha = 0.05$)的 472、502、601、738、827、850、1 052、1 412、2 256、2 394 nm 共 10 个特征波长作为候选辅助变量进行 COK 分析。其中波长 1 412 nm 与土壤重金属 Hg 含量相关性最高(r 为 -0.637),其余波长 $|r|$ 均小于 0.5。可见,通过消除共线性问题,也剔除了大量相关性比较高的波长。

2.2 土壤重金属 Hg 含量 COK 分析

2.2.1 预测模型对比

利用候选辅助变量采用“类回归”方法,共进行 10 次单变量 COK、9 次双变量 COK 和 8 次三变量 COK 分析。将 COK 分析的模型参数绘制成散点图(图 4)。其中,图 4a 为单变量 COK 模型 R^2 和 $|r|$ 关系图,图 4b 为模型 RMSE 和 MAE 关系图;为便于比较,在单变量 COK 模型散点图中加入 OK 模型参数(图 4b)、在双变量 COK 模型散点图中加入波长 1 412 nm 协同的 COK1 模型参数(图 4c、4d)、在三变量 COK 模型散点图中加入波长 1 412 nm 和 1 502 nm 协同的 COK2 模型参数(图 4e、4f)。

在 10 个单变量 COK 模型中波长 1 412 nm 与土壤 Hg 含量相关性最高,其 COK 模型 R^2 最大(图 4a)、RMSE 和 MAE 最小(图 4b),说明波长 1 412 nm 作为辅助变量的 COK 模型稳健性最好,模型模拟效果最佳,即该模型为最优模型 COK1。在 9 次双变量 COK 分析中,波长 1 412 nm 和 1 502 nm 作为辅助变量时模型 R^2 最大(图 4c)、RMSE 和 MAE 最小(图 4d),因此该模型最优,即为 COK2。而 1 412、1 502、738 nm 等波长构成的三变量 COK 分析时模型 R^2 最大(图 4e),RMSE 和 MAE 最小(图 4f),该模型即为 COK3。因此,研究区域土壤重金属 Hg 含量 COK 分析的最优辅助变量组合为 1 412、1 502、738 nm,其构成的 COK3 模型最能反映研究区土壤重金属 Hg 含量的空间分布特征。

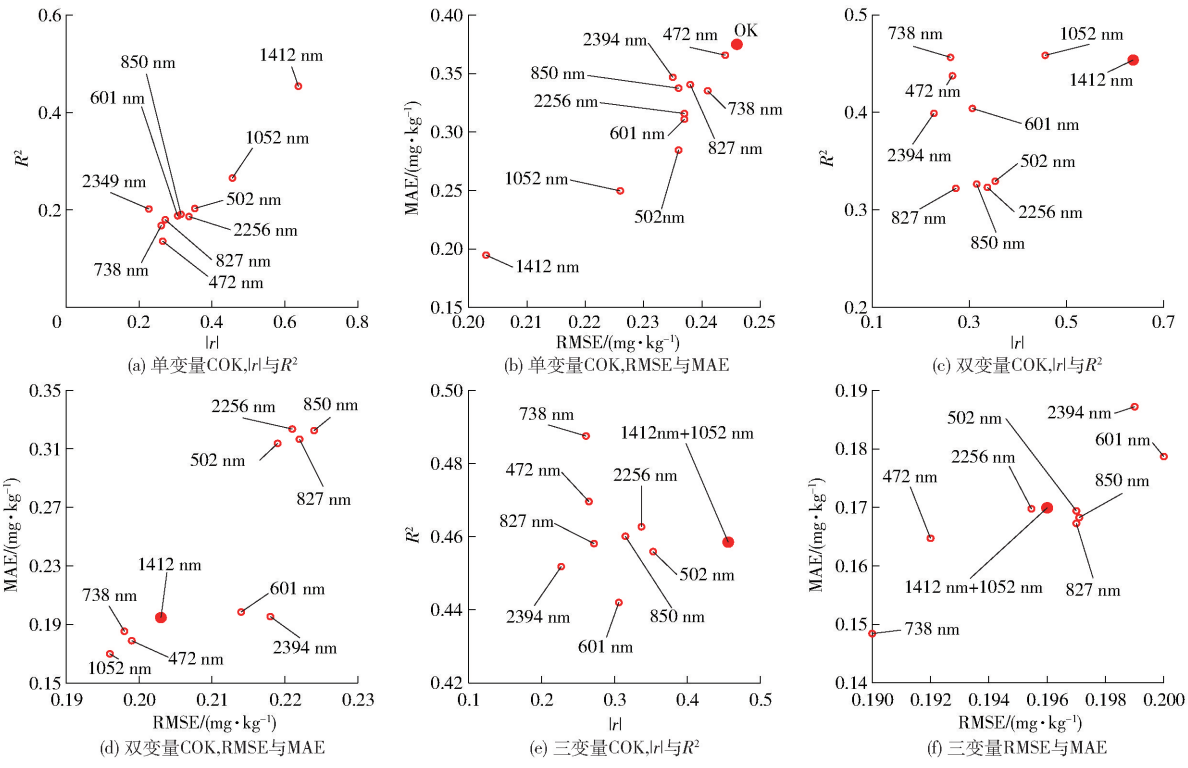


图 4　COK 插值模型检验参数

Fig. 4　Parameters of interpolation models of COK

2.2.2　土壤重金属 Hg 含量空间分布

在 ArcGIS 10.8 中绘制 OK、COK1、COK2 和 COK3 共 4 种方法预测的土壤重金属 Hg 含量空间分布图(图 5),分辨率为 30 m。从图 5 可以看出,在 4 种空间预测方法中土壤重金属 Hg 含量空间分布趋势相似:土壤重金属 Hg 含量总体上呈西北-东南向的“两高”“两低”相间的条带状分布,但局部斑块比较破碎;土壤重金属 Hg 含量高值区主要分布在沙子镇东北部、东南部和中南部,土壤重金属 Hg 含量低值区主要分布在沙子镇北部、西北部和南部。

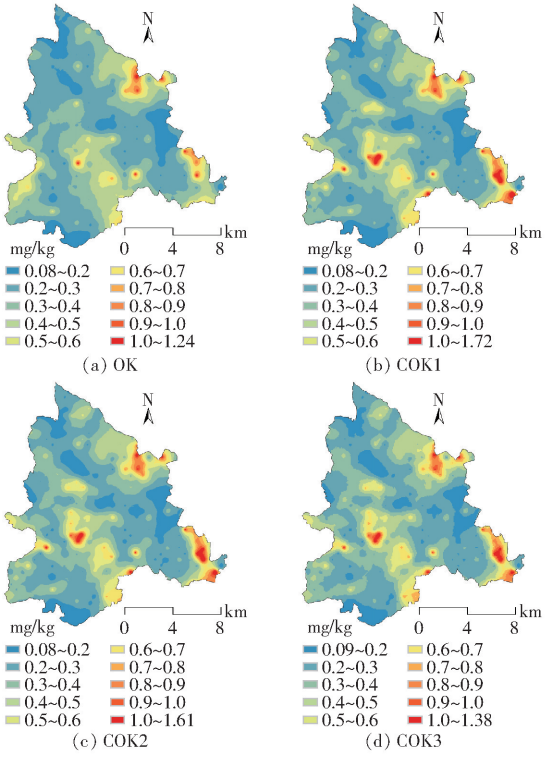


图 5　沙子镇土壤重金属 Hg 含量空间预测图

Fig. 5　Spatial prediction maps of heavy metal Hg content in soil in Shazi Town

2.3　土壤重金属 Hg 含量空间预测精度对比

利用预留的 154 个验证样点,对 OK、COK1、COK2 和 COK3 方法的土壤重金属 Hg 含量空间预测精度进行评价(表 3)。

表 3　土壤重金属 Hg 含量空间预测精度对比

Tab. 3　Comparison of spatial accuracy prediction of heavy metal Hg content in soil

模型	协同变量/nm	R^2	RMSE/(mg·kg^{-1})	MAE/(mg·kg^{-1})
OK		0.117	0.214	0.247
COK1	1 412	0.572	0.193	0.217
COK2	1 412、1 052	0.590	0.182	0.153
COK3	1 412、1 052、738	0.592	0.167	0.154

从表 3 可以看出,OK 模型 R^2 最小,只有 0.117,说明该方法中土壤重金属 Hg 含量预测值与对应验证值差异较大,因而使得其 RMSE 和 MAE 均是 4 种模型中最大的。与 OK 模型相比,COK1、COK2 和 COK3 模型能显著提高模型 R^2,使得土壤重金属 Hg 含量预测值与对应的验证值更接近,降低了预测点的 RMSE 和 MAE,从而提高了模型预测精度;其中

COK3 模型 R^2 最高,为 0.592,RMSE 和 MAE 最低,分别为 0.167 mg/kg 和 0.154 mg/kg,因而预测精度最高。

3 讨论

3.1 辅助变量对预测模型的影响

从单变量 COK 分析来看,模型 R^2 总体上与 $|r|$ 呈正相关(图 4a),模型 RMSE、MAE 总体上与 $|r|$ 呈负相关(图 4a、4b)。在图 4a 中 1 052、1 412 nm 的 R^2 较大,成为“孤点”,而其余的点大致以 $|r| = 0.45$ 为分界相对聚集;在图 4b 中该现象同样存在:1 052、1 412 nm 的 RMSE 和 MAE 较小,模型误差小,在散点图中远离其余相对集中的误差“高值”点。可见,在单一协同克里格分析时,辅助变量与主变量的相关性越强越好,这与孙波等[24]和陈涛等[16]的研究结果一致。

从双变量 COK 分析(图 4c、4d)来看,模型 R^2、RMSE、MAE 与增加变量的 $|r|$ 相关关系不显著,说明增加相关性高的辅助变量对模型的贡献不一定增加。随着第 2 个辅助变量的加入,只有 1 412、1 052 nm 和 1 412、738 nm 作为双变量的 COK 模型 R^2 略大于 COK1 模型 R^2(图 4c),使得其 RMSE 和 MAE 有所减小(图 4d),精度比 COK1 提升(图 4d)。冯家东等[15]在进行县域橡胶园土壤速效钾含量空间变异性研究时发现,有机质含量和高程双变量 COK 模型优于高程单变量 COK,却劣于有机质含量单变量 COK,并且模型拟合精度与协变量选取数量不呈正比,这与本研究的结论基本吻合。从三变量 COK 分析(图 4e、4f)来看,各模型 R^2 均有提升,结合模型的 RMSE、MAE 来看,只有 3 个三变量 COK 模型优于 COK2 模型,其中 1 412、1 502、738 nm 组合的 COK3 为最优模型。738 nm 与土壤重金属 Hg 含量相关系数为 0.261,只比 2 394 nm($r = 0.247$, $p < 0.01$)略大,但其双变量 COK 模型却比其他 $|r|$ 更大的辅助变量的模型效果更好,并且进入到三变量 COK 模型。可见增加的辅助变量对模型的贡献并不完全取决于其相关性,可能取决于主变量与协同变量间的某种内在关系,这值得后续继续探讨。

3.2 辅助变量对预测精度的影响

从 OK 模型预测的验证参数来看,R^2 只有 0.117,RMSE 和 MAE 却高达 0.214、0.247 mg/kg(表 3);从 OK 模型预测效果来看,验证样点预测值最小为 0.15 mg/kg,远高于所有采样点的最小值(0.04 mg/kg),而最大值和变异系数均远小于所有采样点的最大值和变异系数(表 4)。因此,OK 法“平滑效应”明显,并不适合研究区域土壤重金属 Hg 含量的空间预测,这可能与沙子镇复杂多变的岩溶地貌有关[4,25]。因此,后续研究在辅助变量选取时可考虑地形地貌因素。

表 4 不同预测方法土壤重金属 Hg 含量对比

Tab.4 Comparison of soil heavy metal Hg content predicted by different spatial prediction methods

数据源	最小值/(mg·kg^{-1})	最大值/(mg·kg^{-1})	平均值/(mg·kg^{-1})	变异系数/%
所有样点	0.04	1.30	0.346	74.19
OK	0.15	0.72	0.334	34.73
COK1	0.12	1.72	0.365	74.25
COK2	0.18	1.61	0.373	73.19
COK3	0.12	1.38	0.371	64.86

引入高光谱信息的 COK 法能提高研究区土壤重金属 Hg 含量的预测精度。随着协同变量增加,验证样点预测数据与验证数据 R^2 增加,而 RMSE 和 MAE 却减小(表 3),因而预测精度提高。但随着辅助变量增多,R^2 增加与 RMSE、MAE 减小呈减弱趋势(表 3)。从表 4 可以看出,COK 在最值、变异系数上比 OK 更接近于所有采样点的最值、变异系数,因而在一定程度上削弱了“平滑效应”[26]。

4 结束语

在最佳土壤光谱转换方式遴选、特征波长选取基础上,探讨了 COK 法协同变量选取问题,构建了土壤光谱反射率为辅助变量的土壤重金属 Hg 含量空间预测 COK 模型。结果表明,由波长 1 412、1 502、738 nm 构成的三变量 COK 模型稳健性最好、空间预测精度最高。该模型预测的土壤重金属 Hg 含量高值区主要分在沙子镇东北部、东南部、中南部,低值区主要分在沙子镇北部、西北部、南部。研究区域土壤重金属 Hg 含量总体上呈西北-东南向的“两高”“两低”条带状相间分布,但局部斑块比较破碎。研究表明,增加有效的辅助变量可以提高土壤重金属含量空间预测模型稳健性与预测精度,但辅助变量数量大于 2 个后模型预测精度提高幅度减弱。

参 考 文 献

[1] 李硕,王雅晋,覃卫林,等. 基于近地传感光谱协同的土壤重金属含量空间分布预测方法[J]. 农业机械学报,2025,56(3):451-457.
LI Shuo, WANG Yajin, QIN Weilin, et al. Prediction method for soil heavy metal content based on covariates over proximally

sensed spectra[J]. Transaction of the Chinese Society for Agricultural Machinery,2025,56(3):451 – 457. (in Chinese)
[2] YANG Qiyong,JIANG Zhongcheng,LI Wenjun,et al. Prediction of soil organic matter in peak-cluster depression region using Kriging and terrain indices[J]. Soil and Tillage Research,2014,144:126 – 132.
[3] 邝珊,胡月明,刘振华,等. 基于协同克里格的县域耕地质量监测点优化布设[J]. 农业资源与环境学报,2021,38(6):1020 – 1028.
KUANG Shan,HU Yueming,LIU Zhenhua,et al. Optimal layout of county scale monitoring points for cultivated land quality based on coKriging[J]. Journal of Agricultural Resources and Environment,2021,38(6):1020 – 1028. (in Chinese)
[4] ROSNER R,MENDELSON A,RONEN R. Geostatistical mapping of precipitation from rain gauge data using atmospheric and terrain characteristics[J]. Journal of Applied Meteorology,2001,40(40):1855 – 1877.
[5] LI M S B,TANDUGON H M F,YALES N A P,et al. Field-scale spatial variability and uncertainty mapping of soil pH using ordinary Kriging and coKriging with auxiliary soil properties[J]. International Journal of Design & Nature & Ecodynamics,2024,19(6):1872 – 1885.
[6] WU J,NORVELL W A,HOPKINS D G,et al. Improved prediction and mapping of soil copper by Kriging with auxiliary data for cation-exchange capacity[J]. Soil Science Society of America Journal,2003,67(3):919 – 927.
[7] FU P H,YANG Y,ZOU Y S. Prediction of soil heavy metal distribution using geographically weighted regression Kriging[J]. Bulletin of Environmental Contamination and Toxicology,2022,108:344 – 350.
[8] 江叶枫,郭熙. 基于多源辅助数据和神经网络模型的稻田土壤砷空间分布预测[J]. 环境科学学报,2019,39(3):928 – 938.
JIANG Yefeng,GUO Xi. Prediction of spatial distribution of soil arsenic in paddy fields based on multi-source auxiliary data and neural network model[J]. Acta Scientiae Circumstantiae,2019,39(3):928 – 938. (in Chinese)
[9] 陈元鹏,张世文,罗明,等. 基于高光谱反演的复垦区土壤重金属含量经验模型优选[J]. 农业机械学报,2019,50(1):170 – 179.
CHEN Yuanpeng,ZHANG Shiwen,LUO Ming,et al. Empirical model optimization of hyperspectral inversion of heavy metal content in reclamation area[J]. Transaction of the Chinese Society for Agricultural Machinery,2019,50(1):170 – 179. (in Chinese)
[10] 林楠,刘翰霖,孟祥发,等. 基于高光谱的黑土区土壤重金属含量估测[J]. 农业机械学报,2021,52(3):218 – 225.
LIN Nan,LIU Hanlin,MENG Xiangfa,et al. Hyperspectral estimation of heavy metal contents in black soil region[J]. Transaction of the Chinese Society for Agricultural Machinery,2021,52(3):218 – 225. (in Chinese)
[11] 张霞,孙友鑫,尚坤,等. 基于有机质特征谱段的土壤 Cd 含量高光谱遥感反演[J]. 农业机械学报,2024,55(1):186 – 195.
ZHANG Xia,SUN Youxin,SHANG Kun,et al. Soil Cd content retrieval from hyperspectral remote sensing data based on organic matter characteristic spectral bands[J]. Transaction of the CSAE,2024,55(1):186 – 195. (in Chinese)
[12] 李旭青,顾会涛,丁雪瑶,等. 基于波谱响应特征的雄安新区农田土壤重金属含量反演[J]. 农业工程学报,2024,40(4):121 – 128.
LI Xuqing,GU Huitao,DING Xueyao,et al. Inversing heavy metal contents in farmland soil in Xiong'an New Area of China using spectral response characteristics[J]. Transactions of the CSAE,2024,40(4):121 – 128. (in Chinese)
[13] 张秋霞,张合兵,刘文锴,等. 高标准基本农田建设区域土壤重金属含量的高光谱反演[J]. 农业工程学报,2017,33(12):230 – 239.
ZHANG Qiuxia,ZHANG Hebing,LIU Wenkai,et al. Inversion of heavy metals content with hyperspectral reflectance in soil of well-facilitied capital farmland construction areas[J]. Transactions of the CSAE,2017,33(12):230 – 239. (in Chinese)
[14] 李文军,杨奇勇,彭保发,等. 西南岩溶区土壤全氮含量的空间变异分析[J]. 农业机械学报,2014,45(9):150 – 154.
LI Wenjun,YANG Qiyong,PENG Baofa,et al. Spatial variability of total soil nitrogen content in Karst area of southwest China [J]. Transaction of the Chinese Society for Agricultural Machinery,2014,45(9):150 – 154. (in Chinese)
[15] 冯家东,吴炳孙,王晶晶. 基于协同克里格的橡胶园土壤速效钾空间变异性[J]. 应用生态学报,2022,33(4):915 – 921.
FENG Jiadong,WU Bingsun,WANG Jingjing. Spatial variability of soil available potassium in rubber plantation based on coKriging[J]. Chinese Journal of Applied Ecology,2022,33(4):915 – 921. (in Chinese)
[16] 陈涛,常庆瑞,刘京. 基于光谱信息辅助的污灌区农田土壤镉协同克里格分析[J]. 光谱学与光谱分析,2013,33(8):2157 – 2162.
CHEN Tao,CHANG Qingrui,LIU Jing. Study of spatial interpolation of soil Cd contents in sewage irrigated area based on soil spectral information assistance[J]. Spectroscopy and Spectral Analysis,2013,33(8):2157 – 2162. (in Chinese)
[17] TRIANTAFILIS J,ODEH I O A,MEBRATNEY A B. Five geostatistical models to predict soil salinity from electromagnetie induction data across irrigated cotton[J]. Soil Science Society of America Journal,2001,65(3):869 – 878.
[18] YATES S R,WARRICK A W. Estimating soil water content using coKriging[J]. Soil Science Society of America Journal,1987,51(1):23 – 30.
[19] 冯上奇,袁全春,黄凯,等. 基于混合蛙跳算法的果园土壤全氮含量高光谱预测[J]. 农业机械学报,2025,56(6):277 – 275.
FENG Shangqi,YUAN Quanchun,HUANG Kai,et al. Hyperspectral estimation of total nitrogen content in orchard soil based on shuffled frog leaping algorithm[J]. Transaction of the Chinese Society for Agricultural Machinery,2025,56(6):277 – 275. (in Chinese)

(下转第 676 页)

Economic Belt during 1990—2020[J]. Transactions of the CSAE, 2023, 39(23): 247 - 258. (in Chinese)
[19] 王越,宋戈,吕冰. 基于多智能体粒子群算法的松嫩平原土地利用格局优化[J]. 资源科学, 2019, 41(4): 729 - 739.
WANG Yue, SONG Ge, LÜ Bing. Optimization of land-use pattern based on multi-agent particle swarm optimization in the Song-Nen Plain region[J]. Resources Science, 2019, 41(4): 729 - 739. (in Chinese)
[20] 周浩,雷国平,杨雪昕,等. 基于 AgentLA 模型的农田精准灌溉管理分区研究[J]. 水土保持学报, 2018, 32(1): 274 - 279,285.
ZHOU Hao, LEI Guoping, YANG Xuexin, et al. Study on precision irrigation management zones in farmland according agent-based model for optimal land allocation[J]. Journal of Soil and Water Conservation, 2018, 32(1): 274 - 279, 285. (in Chinese)
[21] 陈逸敏,黎夏,刘小平,等. 基于耦合地理模拟优化系统 GeoSOS 的农田保护区预警[J]. 地理学报, 2010, 65(9): 1137 - 1145.
CHEN Yimin, LI Xia, LIU Xiaoping, et al. Coupling geosimulation and optimization (GeoSOS) for zoning and alerting of agricultural conservation areas[J]. Acta Geographica Sinica, 2010, 65(9): 1137 - 1145. (in Chinese)
[22] 张莹,雷国平,张弘强,等. 微观尺度分析挠力河流域耕地利用水土资源匹配时空动态[J]. 农业工程学报, 2019, 35(8): 185 - 194.
ZHANG Ying, LEI Guoping, ZHANG Hongqiang, et al. Spatiotemporal dynamics of land and water resources matching of cultivated land use based on micro scale in Naoli River Basin[J]. Transactions of the CSAE, 2019, 35(8): 185 - 194. (in Chinese)
[23] 胡金虎,丁建丽, 张子鹏,等. 近 30 年吐鲁番哈密地区植被生态需水估算[J]. 生态学报, 2024, 44(19): 8699 - 8715.
HU Jinhu, DING Jianli, ZHANG Zipeng, et al. Estimation of vegetation ecological water demand in Tuha area in the past 30 years[J]. Acta Ecologica Sinica, 2024, 44(19): 8699 - 8715. (in Chinese)
[24] 赵建刚. 土地利用变化对横排头流域蒸散发的影响研究[J]. 中国农村水利水电, 2015(9): 68 - 72,76.
ZHAO Jiangang. Research on the effect of land use change on evaporation of Hengpaitou watershed[J]. China Rural Water and Hydropower, 2015(9): 68 - 72, 76. (in Chinese)
[25] 周浩,胡凌,陈藜藜,等. 衡邵干旱走廊耕地种植结构水分供需评估及其优化[J]. 资源科学, 2024, 46(5): 1032 - 1044.
ZHOU Hao, HU Ling, CHEN Lili, et al. Evaluation of water supply and demand and optimization under the planting structure of cultivated land in the Hengshao Arid Corridor[J]. Resources Science, 2024, 46(5): 1032 - 1044. (in Chinese)

(上接第 657 页)

[20] BABAK O, DEUTSCH C V. Improved spatial modeling by merging multiple secondary data for intrinsic collocated coKriging [J]. Journal of Petroleum Science and Engineering, 2009, 69: 93 - 99.
[21] GHADERMAZI J, SAYYAD G, MOHAMMADI J, et al. Spatial prediction of nitrate concentration in drinking water using pH as auxiliary coKriging variable[J]. Procedia Environmental Sciences, 2013, 3: 130 - 135.
[22] YANG Q Y, JIANG Z C, MA Z L, et al. Spatial prediction of soil water content in Karst area using prime terrain variables as auxiliary coKriging variable[J]. Environmental Earth Sciences, 2014, 72(11): 4303 - 4310.
[23] ZENG C Y, YANG L, ZHU A X, et al. Mapping soil organic matter concentration at different scales using a mixed geographically weighted regression method[J]. Geoderma, 2016, 281: 69 - 82.
[24] 孙波,宋歌,曹尧东. 丘陵区水稻土 Cu 污染空间变异的协同克里格分析[J]. 农业环境科学学报, 2009, 28(5): 865 - 870.
SUN Bo, SONG Ge, CAO Raodong. CoKriging analysis of spatial variability of Cu pollution in paddy soils in a hilly region[J]. Journal of Agro-Environment Science, 2009, 28(5): 865 - 870. (in Chinese)
[25] CHAPLOT V, DARBOUX F, BOURENNANE H, et al. Accuracy of interpolation techniques for the derivation of digital elevation models in relation to landform types and data density[J]. Geomorphology, 2006, 77(1 - 2): 126 - 141.
[26] YAMAMOTO J K. Correcting the smoothing effect of ordinary Kriging estimates[J]. Mathematical Geology, 2005, 37(1): 69 - 94.