

DOI: 10.5846/stxb201609281969

江振蓝, 杨玉盛, 沙晋明. 福州市土壤铬含量高光谱预测的 GWR 模型研究. 生态学报, 2017, 37(23): 8117-8127.

Jiang Z L, Yang Y S, Sha J M. Study on GWR model applied for hyperspectral prediction of soil chromium in Fuzhou City. Acta Ecologica Sinica, 2017, 37(23): 8117-8127.

福州市土壤铬含量高光谱预测的 GWR 模型研究

江振蓝^{1,2}, 杨玉盛¹, 沙晋明^{1,*}

1 福建师范大学地理科学学院, 地理学博士后科研流动站, 福州 350007

2 闽江学院地理科学系, 福州 350108

摘要:通过系统分析不同光谱分辨率和光谱变换对土壤铬高光谱预测模型的不确定性影响, 筛选出最优的光谱分辨率及光谱变量进行土壤铬含量预测的地理权重回归(GWR)模型构建, 利用该模型进行福州市土壤铬含量预测, 并将预测结果与普通最小二乘法回归(OLS)结果进行比较分析, 探讨 GWR 模型在土壤铬高光谱预测中的适用性及局限性。结果表明: (1) 在 10 nm 分辨率尺度下, 以土壤全铬含量为因变量, 反射率的二阶微分和反射率倒数的二阶微分为自变量构建的 GWR 模型对土壤铬预测的效果最好。GWR 模型的 R^2 和调节 R^2 分别为 0.821 和 0.716, 较 OLS 模型分别提高了 0.529 和 0.450, 而 AIC 值为 720.703, 较 OLS 模型减少了 22 个单位, 残差平方和仅为 OLS 模型的 1/4, 说明 GWR 模型的预测效果较 OLS 模型有了显著提高。(2) 土壤铬预测模型的精度受光谱分辨率影响。对于 OLS 预测模型来说, 3 nm 分辨率的模型预测效果最好, 而对于 GWR 预测模型来说, 10 nm 分辨率的模型不仅预测效果最好, 其相较于 OLS 模型的改善作用显著, 为土壤铬含量 GWR 预测的最佳光谱分辨率。(3) 光谱的一阶微分变换可以有效增强土壤铬的光谱特征, 而其余的光谱变换对土壤铬的光谱特征则未起到增强作用, 但可以很好地提高模型的预测效果。(4) 研究得出土壤铬 GWR 模型预测的最佳光谱分辨率为 10 nm, 为 EO-1 Hyperion 影像的光谱分辨率, 而且随着采样点的增加, GWR 模型的预测效果趋于稳定, 适合空间异质性大的区域尺度土壤铬预测。故该模型与高光谱影像结合, 实现模型从实验室尺度向区域尺度的推广, 为格网尺度土壤铬的空间预测提供可能。

关键词:土壤重金属铬; GWR 模型; 高光谱; 光谱分辨率; 光谱变换

Study on GWR model applied for hyperspectral prediction of soil chromium in Fuzhou City

JIANG Zhenlan^{1,2}, YANG Yusheng¹, SHA Jinming^{1,*}

1 Center for Post-doctoral Studies of Geographical Science, School of Geographical Science, Fujian Normal University, Fuzhou 350007, China

2 Geographical Sciences Department, Minjiang University, Fuzhou 350108, China

Abstract: Inversion models applied for hyperspectral prediction of soil chromium include univariate regression, multiple linear regression, principal component regression, and partial least squares regression models. They are mostly based on the presumed homogeneous influence of heavy metal content on spectral reflectance at different locations. This presumption, however, ignores the spatial heterogeneity of correlation between soil chromium and spectral variables. In contrast, Geographically Weighted Regression (GWR) model effectively reveals the spatial heterogeneity among different variables, as is evidenced in many studies involving the spatial prediction of soil properties. In this study, we first analyzed the influence of different spectral resolutions and transformations on soil chromium-targeted hyperspectral prediction model. Thereafter, optimal spectral resolution and variables were selected to establish the GWR model for prediction of soil chromium content in

基金项目:国家自然科学基金青年基金项目(41601601); 福建省自然科学基金项目(2016J01194); 科技部国际合作重大专项(247608); 欧亚土地保护研究国际大学合作项目(561841-EPP-1-2015-1-IT-EPPKA2-CBHE-JP)

收稿日期:2016-09-28; **网络出版日期:**2017-08-14

* 通讯作者 Corresponding author. E-mail: jmsha@fjnu.edu.cn

Fuzhou City. In addition, the applicability and limitations of the model were assessed by comparing the predictions based on GWR and Ordinary Least Squares Regression (OLS) models separately. The conclusions finally drawn from the study are as follows: (1) At a resolution of 10 nm, with soil chromium content as a dependent variable and the second derivative of reflectance and reflectance reciprocal as independent variables, the GWR model displayed the best prediction performance. The values of R^2 and the adjusted R^2 were 0.821 and 0.716, respectively, which showed an increase of 0.529 and 0.450, respectively, above the corresponding values in the OLS model. The AIC was decreased by 22 units to 720.703, and the residual sum of squares was decreased by three quarters, an indication of significant improvement of the prediction performance. (2) The spectral resolution exerted obvious influence on the accuracy of chromium prediction models. The GWR model, with a spectral resolution of 10 nm, as against the OLS model, with a resolution of 3 nm, showed optimal prediction outcome and an evident increase in accuracy. The best resolution for the GWR model was 10 nm. (3) The spectral transformation of first-order differential effectively enhanced the spectral features of soil chromium. Whereas other spectral transformations failed to enhance the features, they significantly improved the prediction performance. (4) The optimal spectral resolution of 10 nm for GWR-based soil chromium prediction was up to the level of EO-1 Hyperion images. Moreover, the prediction performance of the GWR model showed a tendency to stabilize with the increase in the number of sample sites, which is suitable for soil chromium prediction in the regions featuring great spatial heterogeneity. Therefore, with hyper-spectral images, the application of GWR model can be extended from laboratory to the regional scale, making the spatial prediction of soil chromium on grid basis feasible.

Key Words: soil heavy metal chromium; GWR model; hyper-spectral; spectral resolution; spectral transformation

重金属污染已成为当今土壤污染中污染面积最广、危害最大的环境问题之一^[1-4]。铬元素是国际社会公认的 3 种致癌金属之一,近年来,随铬盐、皮革、印染、电镀等涉铬工业的发展以及污水灌溉的影响,土壤铬污染日益严重^[5-8],铬已成为土壤的“优先监测污染物”之一^[9]。传统的土壤重金属铬污染调查主要基于野外实地采样,实验室化学分析的方法,这些方法不仅费时费力,且仅适用于小尺度监测,无法满足土壤铬空间信息快速获取的要求。高光谱遥感技术由于能同时获得精细的几乎连续的光谱,从而能够根据地物的光谱特征对地物进行反演和识别,为快速获取土壤铬信息提供了可能^[10-12]。土壤铬高光谱预测的机理在于高光谱遥感以其获取的连续、精细的反射光谱有可能捕捉到铬元素的光谱吸收特征,通过分析土壤铬的可见光-近红外、中红外等波段的光谱特征,选择土壤铬响应的敏感波段,从而构建模型对土壤铬进行定量预测。

目前,用于土壤铬高光谱预测的模型主要有单变量回归模型^[13-15]、多元线性回归模型^[16-19]、主成分回归法^[18]、偏最小二乘法^[13,17,20-23]等。其中,偏最小二乘回归法提供了一种多对多线性回归建模的方法,能够在波段个数较大且存在严重自相关的情况下进行回归模型建模,较好地解决了单变量回归模型信息利用不全及多元线性回归面临的多重共线性问题,已成为土壤重金属铬高光谱预测应用最广的模型^[24]。前人构建模型的前提是空间平稳性,即假定研究区内土壤重金属含量与光谱反射率的相关关系在研究区内是相同的,模型系数在研究区内是不变的。然而,土壤光谱特征是土壤有关性质的综合反映,土壤并非一个均质体,而是一个时空连续的变异体,土壤重金属含量的空间分布非常复杂,受成土母质、高程、土地利用方式、工业布局、路网、污水灌溉等因素的影响,具有高度的空间异质性^[25-33]。而且除重金属外,土壤光谱还受到土壤结构和成分、植被等环境变量影响,故在不同的研究区域,不同的位置,由于土壤类型、组分和污染水平不同,土壤重金属含量与光谱特征的关系也将发生变化,前人构建模型的空间平稳性前提与实际情况不相吻合,使得不同研究区所得结论有可能是不同的。如 Dong 等^[23]利用偏最小二乘法进行苹果园土壤的重金属预测研究中认为,与土壤有机质、PH 值相关性较强的 Cu 和 Zn 元素预测效果要好于 Pb 和 Cr 元素,而 Wu 等^[11]利用偏最小二乘法对南京郊区土壤重金属预测中发现亲 Fe 重金属 Ni, Cu, Cr 和 Hg 的预测精度高于 Pb, Zn 和 As 元素, Song 等^[21]在对农业土壤重金属预测研究则得出与土壤氧化铁、粘土、有机质含量相关性较强的 Cr、Cu 和 As 元素

的预测效果要好于 Cd、Pb 和 Hg 元素。故前人构建的土壤铬高光谱模型由于忽视土壤铬与光谱特征关系的空间非平稳性,虽然在各自的研究区取得了较好的结果,却很难在其他区域推广。

地理权重回归 (Geographically Weighted Regression, GWR) 模型^[34],采用局部估计回归模型,其核心思路是采样点对其附近点的特征的影响要大于离其较远的点,点位的回归系数不再是利用全局信息获得,而是利用邻近观测值的样本数据进行局部回归估计得到的。该方法克服了普通多元回归方法的缺点,它将数据的空间位置嵌入到回归参数中,使得对空间估值问题更合乎实际^[35-38]。本文将地理权重回归模型引入到土壤重金属铬的高光谱预测中,并通过分析不同光谱分辨率及光谱变换对模型构建的不确定性影响,筛选出最优光谱分辨率及光谱变换方法,构建有效的土壤铬的 GWR 预测模型,为 GWR 模型在土壤铬高光谱预测中的应用提供理论依据。

1 数据来源及其处理

1.1 土壤样品采集和分析

福州市位于我国东南沿海,东经 118°08′—120°31′,北纬 25°15′—26°29′,全区面积为 11968 km²。属于亚热带海洋性季风气候,年均温在 16—20℃,年降水量为 900—1200 mm。境内多山,濒临海洋,地势自东向西倾斜,地形起伏大,成土条件复杂。土壤类型主要有赤红壤、红壤、黄壤及水稻土等,呈酸性。本研究在福州市(除平潭县外),约 11597 km² 范围内采集土壤样本。样点布设主要是以环境保护部和中国科学院于 2012 年 1 月启动的“全国生态环境十年变化(2000—2010 年)遥感调查与评估”项目布设的福建省野外核查点为基础进行的,核查点主要由项目组采用分层抽样方法进行统一布设,分层抽样第一层次为全国,第二层为植被气候分区。样本的各区分以土地覆盖图斑密度为依据,以空间随机分布为原则分配空间位置,在福建省共布设 1317 个核查点,其中 160 个布设在福州市。本项目根据核查点可到达程度和采样的可行性,并结合福州市




图 1 研究区与采样点分布

Fig.1 Study area and sample sites

地形特征、土地覆盖类型及各地类相应的面积,确保研究区内具有代表性的地类均有重复采样点布设的前提下,共采集 131 个 0—20 cm 土壤表层土样,并利用 GPS 记录高程,样点分布较为均匀(图 1)。样点包含红壤、黄壤、赤红壤、水稻土等土壤类型,并涵盖了林地、草地、耕地、建设用地、裸露地等土地覆盖类型。每个采样点混合后取 500 g 土样,经实验室风干,去除沙砾及动植物残体后,研磨,过 100 目尼龙筛。每个样品分成两份,一份用来进行化学分析,另一份用来进行光谱分析。土壤全铬含量采用电感耦合等离子质谱 (ICP-MS, 美国 Thermo Electron) 进行测定。

1.2 土壤光谱测定及其预处理

土壤样品光谱测定采用美国 ASD (Analytical Spectral Device) 公司生产的地物光谱仪 FieldSpec 3 在室内测量,以 1000 W 的卤光灯为光源,采用 15° 的光源照射角度、15 cm 的探头距离及 30 cm 的光源距离,从垂直于土壤表面的方向进行土壤反射光谱测量,并利用 40 cm×40 cm 的白板进行定标,获取绝对反射率。该光谱仪波段范围为 350—2500 nm,在 350—1100 nm 和 1000—2500 nm 范围内的光谱采样间隔分别为 1.4 nm 和 2 nm,光谱重采样后的间隔为 1 nm,输出 2151 个波段。每个土样采集 10 条光谱曲线,利用 ViewSpec Pro 软件剔除异常曲线后取光谱反射率平均值作为样本的原始反射率光谱值^[15]。光谱预处理主要包括:1) 利用

Savitzky-Golay 平滑对曲线进行处理,以消除光谱曲线上存在的“毛刺”噪声;2)对平滑后的数据分别以 1、2、3、4、5、6、7、8、9、10 nm 进行算术平均运算进行重采样,分别获得 1、2、3、4、5、6、7、8、9、10 nm 光谱分辨率的土壤光谱反射率,以分析不同光谱分辨率对模型构建的影响。

1.3 土壤光谱变换与特征波段选取

为有效消除背景噪声,突出光谱的特征值,本文对光谱反射率(Spectral Reflectance, SR)进行以下变换:一阶微分(First Derivative, FD)、二阶微分(Second Derivative, SD)、倒数变换(Reciprocal Transformation, RT)、倒数的一阶微分(RTFD)、倒数的二阶微分(RTSD)、倒数对数变换(吸光率, Absorbance Transform, AT)、倒数对数的一阶微分(ATFD)、倒数对数的二阶微分(ATSD)及连续统去除(Continuum Removal, CR)等。利用土壤全铬含量与变换后的光谱数据进行相关分析,筛选出相关系数最大的光谱特征波段。在不同光谱分辨率尺度下,以全铬含量为因变量,各光谱特征值为自变量,通过逐步回归分析方法,筛选出共线性小的变量参与模型的构建。

2 GWR 模型

GWR 是由 Fotheringham 等^[34]提出的一个空间变参数模型,是对普通最小二乘法回归(Ordinary Least Squares Regression, OLS)模型(式 1)的空间扩展,将数据的地理位置嵌入到回归参数之中,使得参数可以进行局部估计,扩展后的模型如式 2。

$$y_i = \beta_0 + \sum_{k=1}^k \beta_k x_{ik} + \varepsilon_i \quad (1)$$

$$y_i = \beta_0(\mu_i, \nu_i) + \sum_{k=1}^k \beta_k(\mu_i, \nu_i) x_{ik} + \varepsilon_i \quad (2)$$

式中, y_i 为样点 i 的因变量, x_{ik} 为第 i 个样点上第 k 个变量的观测值, (u_i, v_i) 为样点 i 的地理空间坐标, $\beta_0(\mu_i, \nu_i)$ 为回归的常数项, $\beta_k(u_i, v_i)$ 为第 i 个采样点上的第 k 个回归参数, ε_i 为误差项。如果 $\beta_k(u, v)$ 在空间保持不变,则模型(式 2)就变为全局模型(式 1)。

GWR 模型中的 $\beta_k(u_i, v_i)$ 参数估算采用加权最小二乘法实现,用矩阵形式表示为:

$$\hat{\beta}(\mu_i, \nu_i) = [X^T W(\mu_i, \nu_i) X]^{-1} X^T W(\mu_i, \nu_i) Y \quad (3)$$

式中, $W(\mu_i, \nu_i)$ 为 $m \times m$ 的空间权重矩阵, X 为 $m \times (n+1)$ 自变量矩阵, Y 为 $m \times 1$ 因变量矩阵。故 GWR 模型中参数的估算关键在于空间权重矩阵的估算,本文采用高斯函数来实现(式(4))。

$$W_{ij} = \left[1 - \left(\frac{d_{ij}}{h} \right)^2 \right]^2 \quad d_{ij} < h \quad (4)$$

$$W_{ij} = 0 \quad d_{ij} \geq h$$

式中, W_{ij} 为由已知点 j 估计待测点 i 时的权重, d_{ij} 为估算点 i 与样点 j 间的欧氏距离, h 为带宽。其中带宽 h 由最小 AIC 信息准则(Akaike Information Criterion)确定。本文的 GWR 回归过程在 Fotheringham 等人开发的 GWR 3.0 软件支持下完成,模型精度评价采用 AIC 准则、调节决定系数(Adjusted R^2)、残差平方和(RSS)等指标进行评价。此外,铬的预测值与实测值间的相关系数(R)也被用来比较 GWR 与 OLS 的预测效果。

3 结果与讨论

3.1 土壤全铬含量的统计分析

研究区土壤全铬含量在 0.75—111.55 mg/kg 之间,平均值为 26.13 mg/kg,标准差为 17.85 mg/kg。土壤全铬含量变化幅度较大,变异系数为 68.31%,在空间分布上呈现出较强的异质性特点,用于建模具有较好的代表性。研究区全铬含量,除处于罗源的一个样本超过国家一级标准自然背景值外^[39],其他样本均未超标,且其平均值低于福建省土壤背景值(41.3 mg/kg)^[40],基本上可代表福州市土壤铬元素背景值,其研究结果可为区域土壤铬元素含量背景值调查提供参考。

3.2 土壤铬含量预测的敏感光谱波段

在不同光谱分辨率尺度下,经变换后的光谱值与全铬含量进行 Pearson 相关分析,筛选出最大相关系数及其对应的光谱特征波段(表 1)。

表 1 福州市土壤铬与变换光谱最大相关系数的特征波段

Table 1 Maximum correlation coefficients between soil heavy metal Cr content and spectral variables in Fuzhou City

光谱分辨率/mm Spectral resolution	光谱 反射率 SR	一阶 微分 FD	二阶 微分 SD	倒数 变换 RT	倒数的一 阶微分 RTFD	倒数的二 阶微分 RTSD	倒数对 数变换 AT	倒数对 数的一 阶微分 ATFD	倒数对 数的二 阶微分 ATSD	连续 统去除 CR
特征波段	2070	1430	1365	2070	1364	1365	2069 2070	1430	435	2218
相关系数	-0.380 **	-0.369 **	-0.300 **	0.368 **	-0.342 **	0.401 **	0.375 **	0.357 **	-0.266 **	0.344 **
特征波段	2070	1430	1422	2070	1430	1368	2070	1430	828	2218
相关系数	-0.379 **	-0.370 **	-0.314 **	0.367 **	0.321 **	-0.314 **	0.375 **	0.357 **	-0.303 **	0.339 **
特征波段	2069	1439	1412	2069	479	1856	2069	1439	1412 1421	2209
相关系数	-0.379 **	-0.382 **	-0.326 **	0.367 **	-0.345 **	-0.314 **	0.375 **	0.365 **	0.290 **	0.343 **
特征波段	1854 1878 2070	2226	1414	2070	414	1854	2070	1438	1854	2218
相关系数	-0.376 **	-0.358 **	-0.331 **	0.365 **	-0.344 **	-0.320 **	0.372 **	0.350 **	-0.304 **	0.336 **
特征波段	1855 1875 1880	1440	1410	2255	410	1450	2070	1440	1450	2215
相关系数	-0.356 **	-0.376 **	-0.335 **	0.365 **	-0.338 **	-0.294 **	0.371 **	0.359 **	-0.313 **	0.324 **
特征波段	2068	2230	1420	2068	410	1450	2068	2230	1420	2218
相关系数	-0.377 **	-0.377 **	-0.342 **	0.365 **	-0.339 **	-0.280 **	0.373 **	0.348 **	0.311 **	0.305 **
特征波段	2067	2228	2214	2067	2228	1449	2067	2228	1442	2214
相关系数	-0.377 **	-0.401 **	-0.365 **	0.365 **	0.322 **	-0.304 **	0.372 **	0.370 **	-0.347 **	0.309 **
特征波段	1854	2230	2214	2014 2254	2230	1446	2070	2230	1446	2214
相关系数	-0.376 **	-0.408 **	-0.376 **	0.363 **	0.336 **	-0.326 **	0.370 **	0.383 **	-0.355 **	0.322 **
特征波段	1853 1871 2068	2230	2212	2014 2068	413	2149	2068	2230	1439	2212
相关系数	-0.375 **	-0.412 **	-0.370 **	0.363 **	-0.339 **	0.304 **	0.371 **	0.386 **	-0.339 **	0.302 **
特征波段	520	2230	1440	360	410	430	2010	2230	1440	2210
相关系数	-0.415 **	-0.434 **	0.351 **	0.357 **	-0.337 **	0.319 **	0.411 **	0.402 **	-0.327 **	0.310 **

** 表示在 0.01 水平(双侧)上极显著相关

由表 1 可知,各变换光谱与土壤铬的最大相关系数在不同光谱分辨率尺度下均达到 0.01 极显著相关水平。土壤铬的光谱特征波段主要位于可见光 410—430 nm 附近(氧化铁的吸收波段),近红外的 1400 nm 以及 1900—2250 nm 附近(黏土矿物和有机质的敏感波段)。分别对全铬含量与有机质和铁含量进行 Pearson 相关分析,土壤铬与有机质、铁含量的相关系数分别为 0.221 和 0.209,均呈 0.01 水平的极显著相关,说明研究区有机质和氧化铁对土壤铬的影响均存在。但随着光谱分辨率的变化,最大相关系数不同,其所对应的特征波段也不尽相同。对于不同光谱变换来说,光谱的一阶微分变换对土壤铬的光谱特征具有较为明显的增强作用,表现为除 2 nm 和 3 nm 分辨率尺度外,一阶微分变换光谱值与土壤铬的最大相关系数均大于原始反射率与铬的最大相关系数。而其余的光谱变换对土壤铬的光谱特征则未起到增强作用,它们与土壤铬的最大相关系数均小于原始反射率与铬的最大相关系数。这与前人的研究结果基本是一致的^[14,18-19,40]。

为消除光谱变量间的多重共线性,以土壤全铬含量为因变量,特征波段的光谱值为自变量,利用逐步线性

回归分析筛选出模型的光谱变量因子,筛选的标准以回归结果的 R^2 和调节 R^2 最大,自变量间的方差膨胀因子 (Variance inflation factor, VIF) 小于 7.5^[42] 为准,结果如表 2 所示。

表 2 利用光谱变量对土壤铬进行逐步线性回归的结果

Table 2 Outcome of stepwise linear regression of soil chromium content by using spectral variables

光谱分辨率 Spectral resolution/nm	模型 Model	决定系数 R^2	调节决定系数 Adjusted R^2	估计误差 Estimation error	F	P
1	常量, SR_2070, RTSD_1365, ATSD_435, CR_2218	0.342	0.316	14.701	16.403	0.000
2	常量, RTSD_1368, AT_2070, ATSD_828, CR_2218	0.314	0.287	15.013	14.435	0.000
3	常量, FD_1439, RTFD_479, RTSD_1856, CR_2219	0.359	0.333	14.515	17.643	0.000
4	常量, SR_1854, RTFD_414, RTSD_1854, CR_2218	0.351	0.325	14.061	17.062	0.000
5	常量, RT_2255, RTFD_410, CR_2215	0.302	0.280	15.089	18.302	0.000
6	常量, FD_2230, RTFD_410	0.274	0.257	15.328	24.128	0.000
7	常量, FD_2228, RTFD_2228	0.173	0.154	16.366	25.614	0.000
8	常量, FD_2230, RT_2254	0.201	0.182	16.081	16.077	0.000
9	常量, SD_2230, RTSD_2149	0.294	0.272	15.168	17.669	0.000
10	常量, SD_1440, RTSD_430	0.292	0.266	15.898	17.499	0.000

由表 2 可知,随着光谱分辨率的降低,参与模型的变量个数呈递减趋势(由 1 nm—4 nm 分辨率的 4 个减少到 6 nm—10 nm 的 2 个)。不同光谱变换对不同光谱分辨率模型构建的作用也不尽相同,即在不同光谱分辨率尺度下,参与模型预测的光谱变量是不同的,但相近光谱分辨率预测模型的光谱变量却较为相近,且以变换后的光谱特征变量为主,如 1 和 2 nm 的预测模型均有 RTSD, ATSD, CR 的参与, 3 和 4 nm 的预测模型均有 RTFD, RTSD, CR 的参与, 6 和 7 nm 预测模型均有 FD, RTFD 的参与, 9 和 10 nm 的预测模型均有 SD, RTSD 的参与。可见,光谱一阶微分变换可以很好地增强土壤铬的光谱特征,而其余光谱变换虽不能增强土壤铬的光谱特征,却可以很好地提高模型的预测精度。从模型预测效果来看,随着光谱分辨率的降低,模型预测效果呈现变差、变好、变差、再变好的趋势,具体表现为 R^2 和调节 R^2 的值由减小、增大、减小、再增大的变化趋势,而估计误差值则呈现变大、变小、变大、再变小的变化趋势。其中,效果最好的为 3 nm 分辨率的预测模型,随光谱分辨率降低,模型预测效果波动式下降,这与徐明星等^[16]的研究结果较为一致。

3.3 土壤铬含量 GWR 预测的最佳光谱分辨率

不同光谱分辨率尺度下,以表 2 模型中的各光谱特征波段为自变量,土壤全铬含量为因变量,分别利用 OLS 法和 GWR 法对土壤全铬含量进行估算。根据模型的 AIC 值、 R^2 、调节 R^2 和 RSS 进行判断(表 3),即效果较好的回归模型具有较小的 AIC 值和 RSS,较大的 R^2 、调节 R^2 ,以此确定土壤铬含量 GWR 预测的最佳光谱分辨率。

表 3 不同光谱分辨率的 OLS 法和 GWR 法的模型参数

Table 3 Parameters of OLS and GWR models of different spectral resolutions

光谱分辨率/nm Spectral resolution	AIC 信息准则 AIC		决定系数 R^2		调节决定系数 Adjusted R^2		残差平方和 RSS	
	OLS	GWR	OLS	GWR	OLS	GWR	OLS	GWR
1	1083.582	1089.355	0.342	0.362	0.316	0.313	27232.343	26407.790
2	1089.077	1092.328	0.314	0.348	0.287	0.298	28399.134	26983.965
3	1080.233	1077.986	0.359	0.412	0.333	0.372	26545.155	24071.696
4	1081.791	1083.449	0.351	0.395	0.325	0.347	26862.723	25034.506
5	1089.231	1093.092	0.302	0.327	0.280	0.284	28913.437	27885.885
6	1092.228	1096.059	0.274	0.288	0.257	0.254	30074.999	29468.624
7	1135.520	1109.181	0.173	0.499	0.154	0.314	34230.124	20754.347
8	1104.779	1108.382	0.201	0.217	0.182	0.180	33098.839	32433.979
9	1107.942	1106.773	0.294	0.580	0.272	0.432	33606.671	17406.571
10	1097.493	1089.866	0.244	0.674	0.226	0.541	31308.282	13486.885

表 3 中各模型均通过 $P < 0.05$ 的 F 检验。从表 3 可知, GWR 预测模型中, 10 nm 分辨率的 GWR 模型预测能力最强, 其后依次为 7 nm、3 nm 和 4 nm。光谱分辨率不同, GWR 相较于 OLS 模型预测精度的提高程度也不同。其中, 7 nm 和 10 nm 分辨率的 GWR 模型较 OLS 模型预测效果有明显提高, 具体表现为这两种光谱分辨率的 GWR 预测 AIC 值较 OLS 模型分别减少了 26.339 和 7.627, 均大于 3 (GWR 模型较 OLS 模型的 AIC 值若能减少 3 个单位, 认为模型有显著改善^[43]), GWR 预测的 R^2 分别提高了 0.326 和 0.430, 调整 R^2 则分别提高了 0.160 和 0.315。而其他光谱分辨率的 GWR 模型预测效果较 OLS 模型则改善效果不显著。这主要是因为 GWR 模型的应用前提是空间非平稳性, GWR 的预测能力及其对 OLS 模型的优化程度取决于该光谱分辨率下土壤铬与光谱变量间相关关系的空间非稳定性程度(表 4)。

表 4 福州市土壤铬与光谱变量间关系的空间非平稳性检验

Table 4 Test of spatial non-stationarity of the relationship between soil chromium and spectral variables in Fuzhou City

光谱分辨率/nm Spectral resolution	常量 Constant		变量 1 Variable 1		变量 2 Variable 2		变量 3 Variable 3		变量 4 Variable 4	
	UQ-LQ	SE	UQ-LQ	SE	UQ-LQ	SE	UQ-LQ	SE	UQ-LQ	SE
1	39.50	37.26	0.02	0.02	0.54	1.01	0.03	0.04	0.04	0.09
2	57.58	29.41	0.90	2.66	5.98	10.94	16.51	27.68	0.07	0.04
3	59.70	50.57	0.59	0.51	0.06	0.13	9.32	3.78	0.07	0.05
4	73.81	44.43	0.02	0.02	0.03	0.04	10.48	6.48	0.08	6.48
5	32.47	27.51	2.20	5.47	0.04	0.07	0.04	0.03		
6	4.37	4.07	0.06	0.20	0.06	0.06				
7	13.64	3.15	1.11	0.41	5.01	1.22				
8	7.86	14.40	0.20	0.26	6.64	2.45				
9	6.18	4.74	0.18	0.22	0.06	0.06				
10	15.78	3.60	277645.03	51064.04	6360.06	1981.41				

表 4 中, 当 GWR 模型变量参数的上四分位数 (upper quartiles, UQ) 与下四分位数 (lower quartiles, LQ) 的值范围 (UQ-LQ 值) 大于 OLS 相应变量参数的两倍标准误差 (standard errors, SE) 时, 土壤重金属与相应光谱变量的关系存在明显的空间非平稳性, 反之, 则空间非平稳性不明显。由表 4 可知, 7 nm 和 10 nm 光谱分辨率的 GWR 变量参数的 UQ-LQ 值均大于 OLS 相应变量参数的 SE 值两倍 ($2 \times SE$), 尤其以 10 nm 分辨率最为显著, 其所有变量参数的 UQ-LQ 值甚至大于 OLS 相应变量参数的 SE 值的三倍, 土壤铬与各光谱变量间关系的空间非平稳性尤为显著, 故该光谱分辨率的 GWR 模型预测能力最强, 7 nm 分辨率预测模型效果次之。这也说明了较大的光谱间隔可以得到更为平滑的反射光谱曲线, 在一定程度上更能充分体现土壤铬与光谱变量间关系的空间分异规律, 有利于提高 GWR 模型的效果。然而随着光谱分辨率的降低, 信息量也将随之减少, 进而影响土壤铬反演精度。如何充分揭示土壤铬与光谱变量间关系的空间分异规律的同时, 又能尽可能包含多的信息量, 是 GWR 模型最优光谱分辨率选择的关键。前人研究中光谱采样间隔从 1—256 nm 不等, 但是不同研究区域选择的采样间隔具有较大的差异^[20], 甚至出现了光谱分辨率越高对土壤铬的定量反演能力越好^[11] 以及光谱分辨率越低模型精度越高^[11] 两种截然相反的矛盾观点。本研究中, GWR 模型以 10 nm 分辨率效果最优, 不仅预测能力最强, 且较 OLS 模型的改善效果显著, 为土壤铬 GWR 预测的最佳光谱分辨率, 故本文在 10 nm 分辨率尺度下, 利用反射率的二阶微分和反射率倒数的二阶微分进行土壤铬元素的 GWR 模型构建。

3.4 土壤铬高光谱预测的 GWR 模型

为尽量保证建模样本与验证样本范围一致, 将 131 个样本数据按全铬含量从大到小排列, 每隔两个样品取一个作为验证样本, 共 43 个 (33%), 其余的 88 个 (67%) 作为建模样本。其中, 88 个建模样本的土壤铬含量分布范围为 (26.35 ± 18.67) mg/kg, 变异系数为 70.85%, 用于模型验证的 43 个样本铬含量分布范围为 (25.68 ± 16.24) mg/kg, 变异系数为 63.24%, 与建模样本的变化幅度较为一致。

在 10 nm 光谱分辨率尺度下,以 1440 nm 的反射率的二阶微分 (SD₁₄₄₀) 和 430 nm 的反射率倒数的二阶微分 (RTSD₄₃₀) 为自变量,土壤全铬含量为因变量,分别构建 OLS 和 GWR 的土壤全铬含量估算模型。模型的预测效果由较小的 AIC 值和残差平方和,较大的 R^2 和调节 R^2 进行判断(表 5)。

表 5 土壤重金属的 OLS 及 GWR 回归的模型参数比较

Table 5 Comparison between parameters of OLS and GWR regression models for soil heavy metal prediction

模型 Model	AIC 信息准则 AIC	决定系数 R^2	调节决定系数 Adjusted R^2	F	P	残差平方和 RSS
OLS	742.016	0.292	0.266	12.136	0.000	21484.197
GWR	720.703	0.821	0.716	5.667	0.010	5441.275

从表 5 可知,GWR 模型的 AIC 值明显小于 OLS 模型,说明利用 GWR 模型进行土壤铬预测的效果要明显好于 OLS 模型。决定系数 R^2 、调整 R^2 和残差平方和进一步证实这一情况。GWR 模型中,光谱变量对土壤铬的回归解释度达 71.6%,较 OLS 模型(解释度为 26.6%),提高了 45%。且 GWR 模型回归的残差平方和为 5441.275,远小于 OLS 模型的 21484.197,进一步说明 GWR 法进行土壤铬预测的模型效果较 OLS 法有了显著的提升。

为了更好地说明所构建模型的有效性,用 43 个未参与建模的采样点数据分别带入构建的 OLS 和 GWR 模型进行土壤铬预测。预测效果选用最大(正负)估计误差($\pm$ MEE)、平均误差(ME)、均方根误差(RMSE)、OLS 和 GWR 模型预测值与实测值的相关系数(R)、回归的决定系数(R^2)来进行评价,相关参数如表 6 所示。

表 6 OLS 和 GWR 模型预测效果的相关指标

Table 6 Correlation indicators of prediction performance of OLS and GWR models

模型 Model	最大负误差 - MEE	最大正误差 + MEE	平均误差 ME	均方根误差 RMSE	相关系数 R	决定系数 R^2	F	P
OLS	-42.231	24.212	0.724	12.463	0.334	0.112	5.11	0.029
GWR	-39.206	17.927	-0.720	15.487	0.641	0.411	28.581	0.000

如果预测误差是无偏的,即预测值与实测值接近,平均误差接近于 0,均方根误差值越小,模型预测精度越高。从表 5 可以看出,OLS 模型和 GWR 模型平均误差绝对值较为接近,均较接近于 0,但 GWR 模型的最大正负误差及均方根误差小于 OLS 模型,说明 GWR 模型的预测精度高于 OLS 模型。验证样本的 GWR 模型预测值与实测值之间的相关系数及 R^2 均远大于 OLS 模型,进一步证实 GWR 模型的预测精度明显高于 OLS 模型。这主要是因为土壤铬的空间分布同时受各种自然因素和人为活动影响,具有复杂的空间变异性和非平稳性,土壤光谱特征则是土壤有关性质的综合反映,故在不同的研究区域,不同的位置,由于土壤类型、组分和污染水平不同,土壤铬含量与光谱特征的关系也可能是不同的。如果使用传统的全局预测模型进行重金属含量的高光谱估算,得到的回归参数将是整个区域内回归参数的平均值,回归结果不能真实地反映二者关系的空间特征。为了探测参数的空间变化,GWR 模型对 OLS 模型进行了扩展,模型假设距离越近的样点其影响越显著,其使用核函数来确定空间依赖性(空间自相关性)的空间范围,并利用距离衰减函数来对此空间范围内样点进行加权计算^[44]。模型允许参数在空间区域上有一定的变化,通过各空间位置上的参数预测值随空间位置的变化情况,可以非常直观地探测空间关系的非平稳性,可以有效地提高土壤铬的高光谱预测精度。目前 GWR 模型已经发展成一门较为成熟的空间统计学技术,这种估算方法不但简单易行,估算结果有明确的解析表示,得到的参数估计还能进行统计检验,同时也有 GWR3.0 和 ArcGIS 10.2 等相对成熟的软件,该方法可为土壤铬的高光谱预测提供新的思路。

3.5 土壤铬 GWR 预测的稳定性分析

为了更好地说明模型预测的效果及其稳定性,将样本数据按全铬含量从大到小排列,设计不同的建模和验证数据样本比例,分别构建土壤铬预测的 GWR 模型和 OLS 模型(表 7),各模型均通过 $P < 0.05$ 的 F 检验。

发现建模样本与验证样本除了比例为 1:1(66 个建模样本)时, GWR 模型与 OLS 模型的拟合效果相差不大, 其他比例进行土壤铬含量预测时, GWR 模型回归的效果均明显优于 OLS 模型。随着建模样本比例的增大, GWR 模型的回归效果呈现提高-下降-提高的变化趋势, 其中以建模样本与验证样本比例为 1:1 时, 效果最差, 比例为 2:1(88 个建模样本)时, GWR 模型的回归效果最佳。比例从 4:1(105 个建模样本)开始, 随着建模样本比例的增大, GWR 模型的回归效果呈较为稳定的增长趋势, 这说明了 GWR 模型在土壤铬含量预测中的表现总体上来说较为稳定, 但建模样本数较少时, 拟合效果可能出现波动现象, 随着建模样本的增加, 其表现逐渐趋于稳定, GWR 模型适合大样本土壤铬的空间拟合。

表 7 采样点密度对模型预测效果的影响

Table 7 Influence of sample site density on prediction performance of models

建模样本与验证样本比例 Ratio of modeling sample to validation sample	AIC 信息准则 AIC		决定系数 R^2		调节决定系数 Adjusted R^2		残差平方和 RSS	
	OLS	GWR	OLS	GWR	OLS	GWR	OLS	GWR
1:1	562.972	565.667	0.260	0.321	0.224	0.246	17162.844	15766.858
2:1	742.016	720.703	0.292	0.821	0.266	0.716	21484.197	5441.275
3:1	850.886	845.320	0.201	0.781	0.176	0.630	27193.180	7468.076
4:1	856.855	853.276	0.296	0.469	0.275	0.389	19862.900	14992.215
5:1	925.751	928.975	0.268	0.683	0.247	0.565	26966.022	11690.957
6:1	957.456	949.972	0.229	0.679	0.208	0.543	29392.550	12234.952
7:1	983.573	969.763	0.227	0.725	0.206	0.562	28768.907	10250.326
1:0	1097.493	1089.866	0.244	0.674	0.226	0.541	31308.282	13486.885

4 结论

(1) 本研究表明 10 nm 光谱分辨率尺度下, 以 1440 nm 的反射率的二阶微分(SD_1440)和 430 nm 的反射率倒数的二阶微分(RTSD_430)为自变量, 土壤全铬含量为因变量, 构建的 GWR 模型对土壤铬含量预测效果最好, 表现为模型具有最大的 R^2 和调节 R^2 值, 最小的残差平方和, 精度较 OLS 模型有显著提高。

(2) 土壤铬预测模型的精度受光谱分辨率影响。对于 OLS 预测模型来说, 3 nm 分辨率的模型预测效果最好, 而对于 GWR 预测模型来说, 10 nm 分辨率的模型不仅预测效果最好, 其相较于 OLS 模型的改善作用显著, 为土壤铬含量 GWR 预测的最佳光谱分辨率。该光谱分辨率即为 EO-1Hyperion 高光谱影像的光谱分辨率。

(3) 光谱变换对模型的预测效果具有明显的提高作用。虽然光谱变换(除光谱一阶微分外)值与土壤铬的最大相关系数均小于原始反射率与铬的最大相关系数, 对土壤铬的光谱特征未起到增强作用, 但在不同光谱分辨率尺度下, 这些变换光谱在重金属铬的预测模型构建中均有较好的表现, 很好地提高土壤重金属铬的预测效果。

(4) GWR 模型的回归效果受建模样本与验证样本比例的影响。GWR 模型在建模样本数较少时, 其预测效果出现波动现象, 随着建模样本的增加, 其表现逐渐趋于稳定, 说明 GWR 模型适合大样本土壤铬的空间拟合。结合 Hyperion 高光谱影像, 解决实验室光谱向卫星影像光谱的尺度转换问题, GWR 模型容易实现从实验室尺度向区域尺度的推广, 为实现大范围格网尺度的土壤铬空间预测提供可能。

参考文献(References):

- [1] Wang Q Y D, Cui Y, Liu X. Instances of soil and crop heavy metal contamination in China. *Soil and Sediment Contamination: An International Journal*, 2001, 10(5): 497-510.
- [2] Wei B G, Yang L S. A review of heavy metal contaminations in urban soils, urban road dusts and agricultural soils from China. *Microchemical Journal*, 2010, 94(2): 99-107.

- [3] Li Z Y, Ma Z W, Van Der Kuijp T J, Yuan Z W, Huang L. A review of soil heavy metal pollution from mines in China: Pollution and health risk assessment. *Science of the Total Environment*, 2014, 468-469: 843-853.
- [4] Zhang X Y, Zhong T Y, Liu L, Zhang X M, Cheng M, Li X H, Jin J X. Chromium occurrences in arable soil and its influence on food production in China. *Environmental Earth Sciences*, 2016, 75(3): 257-257.
- [5] Paul D, Choudhary B, Gupta T, Jose M T. Spatial distribution and the extent of heavy metal and hexavalent chromium pollution in agricultural soils from Jajmau, India. *Environmental Earth Sciences*, 2015, 73(7): 3565-3577.
- [6] Liu H B, Guo P T, Wu W, Wang Z Y. Assessment of soil arsenic, chromium, mercury, and lead at an agricultural landscape scale. *Soil and Sediment Contamination: An International Journal*, 2011, 20(8): 995-1007.
- [7] Landrot G, Tappero R, Webb S M, Sparks D L. Arsenic and chromium speciation in an urban contaminated soil. *Chemosphere*, 2012, 88(10): 1196-1201.
- [8] Gitet H, Subramanian P A, Minilu D, Kiros T, Hilawie M, Gebremariam G, Taye K. Speciation of chromium in soils near Sheba Leather Industry, Wukro Ethiopia. *Talanta*, 2013, 116: 626-629.
- [9] 多克辛. 土壤优先污染物监测方法. 北京: 中国环境科学出版社, 2012: 162-169.
- [10] Araújo S R, Demattê J A M, Vicente S. Soil contaminated with chromium by tannery sludge and identified by vis-NIR-mid spectroscopy techniques. *International Journal of Remote Sensing*, 2014, 35(10): 3579-3593.
- [11] Wu Y Z, Chen J, Wu X M, Tian Q J, Ji J F, Qin Z H. Possibilities of reflectance spectroscopy for the assessment of contaminant elements in suburban soils. *Applied Geochemistry*, 2005, 20(6): 1051-1059.
- [12] Wu Y Z, Chen J, Ji J F, Gong P, Liao Q L, Tian Q J, Ma H R. A mechanism study of reflectance spectroscopy for investigating heavy metals in soils. *Soil Science Society of America Journal*, 2007, 71(3): 918-926.
- [13] Song Y X, Li F L, Yang Z F, Ayoko G A, Frost R L, Ji J F. Diffuse reflectance spectroscopy for monitoring potentially toxic elements in the agricultural soils of Changjiang River Delta, China. *Applied Clay Science*, 2012, 64: 75-83.
- [14] 李淑敏, 李红, 孙丹峰, 周连第, 鲍京. 基于热红外特征光谱的土壤重金属含量估算模型研究. *红外*, 2010, 31(7): 33-38.
- [15] 吴明珠, 李小明, 沙晋明. 亚热带土壤铬元素的高光谱响应和反演模型. *光谱学与光谱分析*, 2014, 34(6): 1660-1666.
- [16] 徐明星, 吴绍华, 周生路, 廖富强, 马春梅, 朱诚. 重金属含量的高光谱建模反演: 考古土壤中的应用. *红外与毫米波学报*, 2011, 30(2): 109-114.
- [17] Lian S, Ji J, Tan D J, Xie H B, Luo Z F, Gao B. Estimate of heavy metals in soil and streams using combined geochemistry and field spectroscopy in Wan-sheng mining area, Chongqing, China. *International Journal of Applied Earth Observation and Geoinformation*, 2015, 34: 1-9.
- [18] 王菲, 曹文涛, 康日斐, 曹见飞, 吴泉源. 基于野外实测光谱的金矿区土壤重金属铬监测研究. *环境污染与防治*, 2016, 38(2): 13-18.
- [19] 龚绍琦, 王鑫, 沈润平, 刘振波, 李云梅. 滨海盐土重金属含量高光谱遥感研究. *遥感技术与应用*, 2010, 25(2): 169-177.
- [20] 刘华, 张利权. 崇明东滩盐沼土壤重金属含量的高光谱估算模型. *生态学报*, 2007, 27(8): 3427-3434.
- [21] Song Y X, Ji J F, Mao C P, Ayoko G A, Frost R L, Yang Z F, Yuan X Y. The use of reflectance visible-NIR spectroscopy to predict seasonal change of trace metals in suspended solids of Changjiang River. *CATENA*, 2013, 109: 217-224.
- [22] 袁中强, 曹春香, 鲍达明, 陈伟, 田蓉, 俄尔, 李华. 若尔盖湿地土壤重金属元素含量的遥感反演. *湿地科学*, 2016, 14(1): 113-116.
- [23] Dong Y W, Yang S Q, Xu C Y, Li Y Z, Bai W, Fan Z N, Wang Y N, Li Q Z. Determination of soil parameters in apple-growing regions by near-and mid-infrared spectroscopy. *Pedosphere*, 2011, 21(5): 591-602.
- [24] Shi T Z, Chen Y Y, Liu Y L, Wu G F. Visible and near-infrared reflectance spectroscopy-An alternative for monitoring soil contamination by heavy metals. *Journal of Hazardous Materials*, 2014, 265: 166-176.
- [25] Huo X N, Zhang W W, Sun D F, Li H, Zhou L D, Li B G. Spatial pattern analysis of heavy metals in Beijing agricultural soils based on spatial autocorrelation statistics. *International Journal of Environmental Research and Public Health*, 2011, 8(12): 2074-2089.
- [26] Krami L K, Amiri F, Sefiyanian A, Shariff A R B M, Tabatabaie T, Pradhan B. Spatial patterns of heavy metals in soil under different geological structures and land uses for assessing metal enrichments. *Environmental Monitoring and Assessment*, 2013, 185(12): 9871-9888.
- [27] Zhong B Q, Liang T, Wang L Q, Li K X. Applications of stochastic models and geostatistical analyses to study sources and spatial patterns of soil heavy metals in a metalliferous industrial district of China. *Science of the Total Environment*, 2014, 490: 422-434.
- [28] Nanos N, Martín J A R. Multiscale analysis of heavy metal contents in soils: Spatial variability in the Duero river basin (Spain). *Geoderma*, 2012, 189-190: 554-562.
- [29] Ağca N. Spatial distribution of heavy metal content in soils around an industrial area in Southern Turkey. *Arabian Journal of Geosciences*, 2015, 8(2): 1111-1123.
- [30] Dragović R, Gajić B, Dragović S, Đorđević M, Đorđević M, Mihailović N, Onjia A. Assessment of the impact of geographical factors on the spatial distribution of heavy metals in soils around the steel production facility in Smederevo (Serbia). *Journal of Cleaner Production*, 2014, 84: 550-562.

- [31] 李清良, 吴倩, 高进波, 马军, 徐秋芳, 俞慎. 基于小流域尺度的土壤重金属分布与土地利用相关性研究——以厦门市坂头水库流域为例. 生态学报, 2015, 35(16): 5486-5494.
- [32] 吴文勇, 尹世洋, 刘洪禄, 潘兴瑶, 宝哲. 污灌区土壤重金属空间结构与分布特征. 农业工程学报, 2013, 29(4): 165-173.
- [33] 全致琦, 陈太政, 段海静, 谷蕾, 马建华. 不同耕作方式对路旁土壤重金属分布的影响——以黄淮平原国道 310 开封段为例. 地理科学, 2014, 34(3): 377-384.
- [34] Fotheringham A, Charlton M, Brunsdon C. The geography of parameter space: An investigation of spatial non-stationarity. *International Journal of Geographical Information Systems*, 1996, 10(5): 605-627.
- [35] Jaber S M, Al-Qinna M I. Global and local modeling of soil organic carbon using Thematic Mapper data in a semi-arid environment. *Arabian Journal of Geosciences*, 2015, 8(5): 3159-3169.
- [36] Propastin P. Modifying geographically weighted regression for estimating aboveground biomass in tropical rainforests by multispectral remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 2012, 18: 82-90.
- [37] Wang K, Zhang C R, Li W D. Predictive mapping of soil total nitrogen at a regional scale: A comparison between geographically weighted regression and cokriging. *Applied Geography*, 2013, 42: 73-85.
- [38] Wang K, Zhang C R, Li W D, Lin J, Zhang D X. Mapping soil organic matter with limited sample data using geographically weighted regression. *Journal of Spatial Science*, 2014, 59(1): 91-106.
- [39] 国家环境保护局. GB/T 15618-1995 土壤环境质量标准. 北京: 中国标准出版社, 2006.
- [40] 陈振金, 陈春秀, 刘用清, 吴瑜端, 杨孙楷, 卢昌义. 福建省土壤环境背景值研究. 环境科学, 1992, 13(4): 70-75.
- [41] 解宪丽, 孙波, 郝红涛. 土壤可见光——近红外反射光谱与重金属含量之间的相关性. 土壤学报, 2007, 44(6): 982-993.
- [42] Qiu Y, Fu B, Wang J, Chen L, Meng Q, Zhang Y. Spatial prediction of soil moisture content using multiple-linear regressions in a gully catchment of the Loess Plateau, China. *Journal of Arid Environments*, 2010, 74(2): 208-220.
- [43] 王库. 基于地理权重回归模型的土壤有机质空间预测. 土壤通报, 2013, 44(1): 21-28.
- [44] Fotheringham A S, Brunsdon C, Charlton M N. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*. New York: Wiley, 2002.