

基于高光谱的黑土区土壤重金属含量估测

林楠¹ 刘翰霖¹ 孟祥发¹ 刘海琪² 杨佳佳³

(1. 吉林建筑大学测绘与勘查工程学院, 长春 130018; 2. 东北大学资源与土木工程学院, 沈阳 110819;
3. 中国地质调查局沈阳地质调查中心, 沈阳 110034)

摘要: 以黑龙江省讷河市采集的 80 份黑土样品和高光谱实测数据为数据源,对黑土中铜(Cu)、锌(Zn)、锰(Mn)重金属元素的光谱反射率及其特征变化进行研究,分析了光谱反射率、光谱反射率一阶微分变换、光谱反射率连续统去除变换、光谱反射率连续统去除一阶微分变换与元素铜、锌、锰含量的相关性,并利用相关系数法提取敏感波段。利用核主成分分析(Kernel principal component analysis, KPCA)方法对高光谱敏感波段数据进行降维及特征提取,将特征信息作为极限学习机(Extreme learning machine, ELM)模型建模的样本数据,构建 KPCA-ELM 估测模型,进行黑土重金属含量的定量估算。结果表明:KPCA 具有较强的非线性特征提取能力,可以有效地选择最佳变量集合,KPCA-ELM 模型预测土壤元素含量效果理想,3 种重金属元素含量估测的决定系数均达到 0.6 以上,其中,锌元素预测精度最高,决定系数和均方根误差分别为 0.805 和 3.275 mg/kg,比特征提取前模型预测精度优化了 14.0% 和 18.5%,说明构建的 KPCA-ELM 模型是一种快速可行的重金属含量高光谱估测方法。

关键词: 黑土区; 重金属; 高光谱; 含量估测

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2021)03-0218-08 **OSID:** 

Hyperspectral Estimation of Heavy Metal Contents in Black Soil Region

LIN Nan¹ LIU Hanlin¹ MENG Xiangfa¹ LIU Haiqi² YANG Jiajia³

(1. College of Surveying and Prospecting Engineering, Jilin Jianzhu University, Changchun 130018, China
2. College of Resources and Civil Engineering, Northeastern University, Shenyang 110819, China
3. Shenyang Institute of Geology and Mineral Resources, China Geological Survey, Shenyang 110034, China)

Abstract: Taking 80 black soil samples collected from Nehe City, Heilongjiang Province, and hyperspectral measured data as data sources, the spectral reflectance and its feature changes of copper (Cu), zinc (Zn), manganese (Mn) in black soil were analyzed, the correlations between four different forms of spectral reflectance, which included original, first-order differential, continuum removal, and first-order derivative of continuum removal and soil Cu, Zn, Mn contents were calculated, and the correlation coefficient method was used to extract sensitive bands. Then the kernel principal component analysis (KPCA) was applied for dimension reduction and feature extraction of hyperspectral sensitive band data, and the feature information was input into extreme learning machine (ELM), and the KPCA-ELM estimation model was constructed to quantitatively estimate the heavy metal contents. The results showed that KPCA had a strong ability to extract nonlinear features and effectively selected the optimal variable set. The KPCA-ELM model was feasible in predicting soil element content and the determination coefficients of the three heavy metal elements were all more than 0.6, where the prediction accuracy of Zn was the highest among the three heavy metal elements. And the determination coefficient and root mean square error were 0.805 and 3.275 mg/kg respectively, which were improved by 14.0% and 18.5% compared with without feature extraction. Therefore, KPCA-ELM model was a fast and feasible method for hyperspectral estimation of heavy metal content.

Key words: black soil region; heavy metal; hyperspectral; content estimation

0 引言

东北黑土区土壤肥沃、养分供应能力强,是我国宝贵的耕地资源。黑土中铜(Cu)、锌(Zn)、锰(Mn)等重金属元素在作物生长过程中起着至关重要的作用,是土壤质量监测的重要指标。重金属元素过量积累会影响土壤微生物多样性,从而破坏土壤肥力和缓冲能力,造成土壤质量下降。因此,快速、准确地估测黑土中的重金属含量对黑土区科学管理和持续保护具有重要意义^[1-2]。近年来,高光谱遥感以其快速、准确的优点成功应用于土壤元素含量的估测计算中,并取得了一定成果^[3-9]。

高光谱遥感通过连续紧密的波段记录土壤光谱信息,其数据量大、信息丰富。由于波段数量较多,使波段之间存在信息冗余现象,从而影响了建模预测结果^[10-11]。目前,大多数研究都是首先计算光谱波段与元素含量的相关系数,然后通过设定相关系数的阈值来选择敏感波段。陈元鹏等^[12]以工矿复垦区为试验区域,通过计算相关系数进行实测高光谱数据的优选,结合实测的土壤重金属含量,采用偏最小二乘、随机森林、支持向量机等回归分析模型进行土壤重金属含量反演试验研究。王金凤等^[13]以喀斯特流域为研究区,基于测定土壤样品的锌元素含量和采集的土壤光谱数据,利用相关分析进一步筛选特征变量,并采用非线性算法揭示光谱敏感波段反射率与重金属元素含量之间的映射关系,从而进行土壤重金属含量估测。由于高光谱测量数据的高维非线性特征,通过设置相关系数阈值提取后的敏感波段仍然可能存在信息冗余,进而影响模型估测精度。核主成分分析(Kernel principal component analysis, KPCA)是一种有效的特征识别和提取方法,它结合了核函数与主成分分析(Principal component analysis, PCA)的特点,具有极强的非线性特征提取能力,常用于高维数据分类和异常识别^[14]。本研究对黑土中铜(Cu)、锌(Zn)、锰(Mn)重金属元素的光谱反射率及其特征进行分析,分别与各元素含量进行相关性计算,引入KPCA方法,进行敏感特征波段选取,与极限学习机(Extreme learning machine, ELM)模型相结合构建元素含量预测模型,并对KPCA降维前后模型的估测精度进行对比分析,以期在黑土区重金属含量高光谱估测研究提供一种高效的方法。

1 材料与方法

1.1 研究区概况

土壤样品采集试验区位于黑龙江省讷河市,该

区地处松辽平原北端,大小兴安岭南缘,是黑土分布的典型区域。区内耕地面积广阔,农产品种类丰富,是甜菜和马铃薯的盛产地。2019年4月在试验区内挑选典型黑土地块,共采集土壤样本80个(图1),采集样品过程中确保采样点距离公路至少150 m,以每个采样点位置为中心,在其周围5 m×5 m范围内进行样品采集,每个采样点位置共采集5份黑土样本,取样深度为15 cm,将样本充分混合后装入采样袋。




图1 研究区样品采集点地理位置
Fig. 1 Location of sample collection points in study area

1.2 元素含量测量及样本划分

将样品中的秸秆、砂砾等杂物剔除,风干后研磨过筛,使得土壤粒径小于0.25 mm,将合格的样品分成2份,1份用于测定土壤元素含量,另1份用于室内高光谱测量^[15]。结合多目标样品分析质量要求等技术规范,在满足规范要求样品分析的检出限、准确度、精密度等技术条件的前提下,参照《土壤农业化学分析方法》,选用X射线荧光光谱法进行土壤铜(Cu)、锌(Zn)、锰(Mn)3种重金属元素含量的测定。对元素含量的测量分析结果进行统计(表1),将80份土壤样品按元素含量由低到高分为20组,每组随机抽取1个样品放入验证集,共20个样品作为验证集,其余60个样品为训练集。

表1 土壤样本重金属含量信息
Tab. 1 Statistics of soil samples heavy metal contents

元素	样本数	最小值/ (mg·kg ⁻¹)	最大值/ (mg·kg ⁻¹)	均值/ (mg·kg ⁻¹)	标准差/ (mg·kg ⁻¹)
Cu	80	13.4	29.8	19.584	1.992
Zn	80	38.5	77.2	58.346	7.142
Mn	80	500	1237	787.013	170.249

1.3 光谱采集及特征变化

在暗室中进行土壤光谱测量,本次试验测量仪器选用ASD FiledSpec4型地物波谱仪,为提高光谱

测量数据的精度,测量中取 5 次光谱测量的均值作为土壤样品的反射光谱数据。由于光谱分辨率较高,波段数较多,相邻波段之间可能存在信息重叠,更容易受到噪声的影响,因此,将光谱数据进行重采样和去噪处理,设置采样间隔为 10 nm。在去噪和

重采样处理的基础上,对原始光谱反射率(R)进行光谱一阶微分交换(FD)、光谱连续统去除变换(CR)、光谱连续统去除一阶微分交换(CR-FD),能够有效突出光谱曲线峰谷,可以快速准确地确定敏感波段(图 2)。




图 2 土壤原始及变换后光谱反射率曲线
Fig. 2 Soil spectral curves of reflectance and its transformation

从图 2 可以看出,采集的黑土样品原始光谱反射率在 0~0.9 之间,各样品光谱曲线波动形状相似,在可见光波段,随着波长的增加,反射率逐渐增加,直到 1 200 nm 处反射率趋于稳定。近红外区土壤光谱反射率总体高于可见光区,两个明显的波谷分布在 1 400 nm 和 1 900 nm 附近,主要是土壤中残留的水分和空气中水蒸气吸收造成的,而在 2 200 nm 处有轻微的凹陷,主要是受土壤中存在粘土矿物的影响。图 2b~2d 为原始光谱经过 3 种不同变换后的光谱曲线,可以看出 3 种变换均可以对原始光谱特征起到放大作用,经变换后反射率在 1 400、1 900、2 200 nm 附近波动更大。

2 模型原理

2.1 极限学习机

极限学习机(Extreme learning machine, ELM)是单隐层前馈神经网络(Single-hidden layer feedforward neural network, SLFN)学习训练的新模型,相比于传统的人工神经网络,ELM 算法的初始化参数少、学习训练速度快,建模过程不需要调整隐含层参数,相当于一个线性参数模式,可以简单地求出系统的最小二乘解^[16-17]。极限学习机的输出函

数定义为^[18-20]

$$f_L(x) = \sum_{i=1}^L \beta_i h(w_i x_j + b_i) = \mathbf{h}(x) \boldsymbol{\beta} \tag{1}$$

其中

$$\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_L) \tag{2}$$
$$\mathbf{h}(x) = (h_1(x), h_2(x), \dots, h_L(x))^T \tag{3}$$
$$h(w_i x_j + b_i) = G(w, b, x) \tag{4}$$

式中 w_i ——隐含层权重
 b_i ——隐含层偏置参数
 $\boldsymbol{\beta}$ —— L 个节点的隐含层到 m 个输出节点之间的输出权向量
 $\mathbf{h}(x)$ ——极限学习机非线性特征映射关系
 $h(w_i x_j + b_i)$ ——第 i 个隐藏节点的输出函数
 $G(w, b, x)$ ——连续函数的非线性映射,即激活函数

$\boldsymbol{\beta}$ 可以通过最小二乘解获得,即

$$\min_{\boldsymbol{\beta} \in \mathbf{R}_{L \times m}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|^2 \tag{5}$$

式中 $\mathbf{H}$ ——隐含层输出矩阵(随机矩阵)
 $\mathbf{T}$ ——训练数据目标矩阵

最小二乘解为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \tag{6}$$

式中 $\mathbf{H}^+$ —— $\mathbf{H}$ 的 Moore-Penrose 广义逆

通常采用奇异值分解法(Singular value

decomposition, SVD) 计算矩阵的 Moore – Penrose 广义逆。由于 ELM 算法随机定义训练数据的数量, 并且每次计算只更新权重而不重新训练样本, 使得 ELM 算法在训练时间和精度上表现十分优异。

2.2 核主成分分析

核函数是处理非线性多维数据统计的有效方法, 核主成分分析是主成分分析改进, 基本思想是将核函数与 PCA 相结合, 有效减少非线性数据的维数。KPCA 的核心思想是将输入的非线性数据转换到高维特征空间 F , 进行主成分分析, 特征空间 F 通常为高维欧氏空间或无穷维 Hilbert 空间^[21-23]。

令 $x_1, x_2, \cdots, x_n \in \mathbf{R}^d$ 为 KPCA 学习的 n 个训练样本, 得到第 i 个经 KPCA 变换后的特征向量为

$$t_i = \frac{1}{\sqrt{\lambda_i}} \gamma_i^T [k(x_1, x), k(x_2, x), \cdots, k(x_i, x), \cdots, k(x_n, x)]^T$$

(7)

其中

$$k(x_i, x) = \begin{cases} (x_i x + 1)^d & \text{(多项式核函数)} \\ \exp\left(-\frac{1}{\sigma^2 \|x_i - x\|^2}\right) & \text{(径向基核函数)} \\ \tanh(-b(x_i x) - c) & \text{(感知器核函数)} \end{cases}$$

(8)

式中 $k(x_i, x)$ ——特征空间 F 中任意两个变量经核函数映射后的内积

γ_i ——核矩阵 K 中特征值对应的标准正交化特征向量




图 3 土壤光谱相关系数曲线

Fig. 3 Correlation coefficient curves of soil spectral

3 基于 KPCA – ELM 模型的土壤重金属含量估测

3.1 相关性分析

分别计算了土壤铜 (Cu)、锌 (Zn)、锰 (Mn) 含量与土壤原始光谱反射率及其变换的相关系数, 并绘制了相关系数曲线 (图 3)。从图 3a 可以看出, 土壤锌 (Zn) 和锰 (Mn) 元素含量与原始光谱反射率的相关系数均为正值, 而铜 (Cu) 元素含量与原始光谱反射率的相关系数则正负均有。与原始光谱反射率相比, 经特征变化后的光谱数据与土壤重金属元素含量的相关性更高, 且特征变化后光谱数据与重金属元素含量的相关系数表现为正、负交叉, 同时波峰和波谷的个数增多, 峰值较多, 各元素的最高相关系数显著提高。

试验中对计算的相关系数进行统计, 并设定相关系数阈值进行敏感波段提取, 将提取的敏感波段作为预测模型的样本输入数据 (表 2)。由表 2 可以看出, 经过不同的光谱特征变换, 元素含量与光谱反射率的相关系数计算结果差别较大, 其中, 土壤铜 (Cu) 元素的最佳变换形式为连续统去除变换, 与光谱反射率的相关系数最高为 0.527, 波长在 2 310 nm 附近; 土壤锌 (Zn) 元素的最佳变换形式为连续统去除一阶微分变换, 相关系数最高为 0.657, 波长在 440 nm 附近; 土壤锰 (Mn) 元素对应的最佳变换形式为连续统去除变换, 相关系数最高为 -0.513, 波长在 2 230 nm 附近。

表 2 土壤元素最大相关系数和敏感波段

Tab.2 Maximum correlation coefficients and sensitive bands

元素	原始光谱	光谱一阶微分变换	光谱连续统去除变换	光谱连续统去除一阶微分变换
最大相关系数	0. 172	0. 434	0. 527	-0. 500
Cu				
波长/nm	600	1 280	2 310	790
数量	0	30	44	38
最大相关系数	0. 535	0. 639	-0. 620	0. 657
Zn				
波长/nm	670	450	2 220	440
数量	172	74	53	61
最大相关系数	0. 390	0. 500	-0. 513	0. 472
Mn				
波长/nm	790	440	2 230	440
数量	198	73	51	49

3.2 核主成分特征波段选择

从相关系数计算结果可以看出(表 2),设定提取阈值后,3 种重金属元素敏感波段的数量依然较多,光谱波段之间仍然存在数据冗余,试验采用 KPCA 方法对光谱敏感波段进行特征提取,得到相互独立的特征变量用于建模预测。利用 KPCA 方法提取特征敏感信息具体步骤如下:①将选取 60 个训练样品的最佳光谱变换形式对应的波段作为样本输入数据,试验中土壤铜(Cu)元素输入波段数为 44 个,土壤锌(Zn)元素输入波段数为 61 个,土壤锰(Mn)元素输入波段数为 51 个,对各元素输入波段数据进行归一化处理。②选择 KPCA 的核函数,计算核矩阵 K ,本次试验核函数选择径向基核函数。③求核矩阵 K 的特征值和特征向量。④计算特征值的累计贡献率 C_i ,设定阈值 K ,当累计贡献率大于阈值时提取对应的前 i 个主成分,累计贡献率阈值 K 设定为 90%。

根据以上步骤进行土壤重金属元素光谱特征主成分提取,计算结果如表 3 所示,从表中可以看出,KPCA 方法特征提取效果显著,铜(Cu)元素用于建模的变量从 44 个降为 17 个,锌(Zn)元素从 61 个降为 24 个,锰(Mn)元素从 51 个降为 19 个(图 4)。

表 3 KPCA 特征提取结果

Tab.3 Results of KPCA feature extraction

元素	特征变换形式	敏感波段数量	主成分数量
Cu	CR	44	17
Zn	CR-FD	61	24
Mn	CR	51	19

3.3 基于极限学习机的重金属含量估测模型

ELM 模型基于 Python 软件平台实现,分别将




图 4 特征信息主成分累计贡献率

Fig.4 Cumulative contribution rate of principal components of feature information

KPCA 方法提取的特征主成分分量和土壤元素含量作为模型建模的输入和输出端,构建训练样本数据集^[24-25]。极限学习机模型初始化参数包括隐含层的权重 w 、偏置参数 b 、神经元个数 N 以及输出类型,试验选择 Guass 函数作为输出函数,权重和偏置参数初始化参数敏感性不强,选择默认缺省参数进行初始化。隐层神经元个数 N 是 ELM 预测模型的重要参数,一般来说隐层神经元个数 N 太小会导致模型拟合不充分, N 太大模型又可能过拟合,导致隐层神经元输出矩阵为稀疏矩阵,所以需要对其进行优化选择,选择决定系数(R^2)作为适应度评价标准。通过迭代计算设置不同神经元个数时预测结果的决定系数(图 5),选取决定系数最大时对应的神经元个数为模型建模的输入值。通过计算得到,铜(Cu)元素预测模型的隐含层神经元个数 N 为 35 时,训练模型决定系数达到最大值 0.744;锌(Zn)元素预测模型的隐含层神经元个数 N 为 49 时,训练模型决定系数达到最大值 0.938;锰(Mn)元素预测模型的隐含层神经元个数 N 为 40 时,训练模型决




图 5 神经元个数与决定系数关系曲线

Fig.5 Relationship curves between number of neurons and determining coefficient

定系数达到最大值 0.767。

3.4 估测结果精度分析

为了对比分析 KPCA – ELM 模型的预测精度，分别计算了核主成分特征提取前后模型训练集和验证集决定系数(R^2)和均方根误差(RMSE)(表 4)。从表 4 可以看出，训练集和验证集土壤锌(Zn)元素含量的预测精度均为最高，经过 KPCA 特征提取后，ELM 模型预测精度有了较大的提升，从验证集结果来看，锰(Mn)元素 R_p^2 变化最为显著，由 0.537 提高至 0.642；锌(Zn)元素的 RMSEP 变化最大，由 4.019 mg/kg 下降至 3.275 mg/kg。

为进一步对比分析 3 种元素模型拟合效果，利

用模型预测值和实测值绘制预测结果(图 6)。从

表 4 元素含量预测模型结果对比
Tab.4 Comparison of element content estimation model results

元素	主成分数量	模型	训练集		验证集	
			R_c^2	RMSEC/ ($\text{mg}\cdot\text{kg}^{-1}$)	R_p^2	RMSEP/ ($\text{mg}\cdot\text{kg}^{-1}$)
Cu	17	ELM	0.653	1.181	0.585	1.251
		KPCA – ELM	0.744	1.015	0.679	1.100
Zn	24	ELM	0.785	3.260	0.706	4.019
		KPCA – ELM	0.938	1.747	0.805	3.275
Mn	19	ELM	0.639	100.162	0.537	122.109
		KPCA – ELM	0.767	80.438	0.642	107.365




图 6 元素含量预测值和实测值

Fig.6 Predicted and measured values of element content

图 6 可以看出，利用 KPCA 进行特征提取后的 ELM 模型的预测值更紧密地分布在 1:1 左右，数据拟合能力和稳定性均有一定程度的提高。同时可以看出，训练集的拟合比验证集效果好，验证集样本点分布相对分散，说明极限学习机模型对训练样本的可靠性和一致分布性要求较高。

4 结论

(1) 对光谱曲线进行不同形式的特征变换可以有效地增强光谱特征、提高光谱反射率与土壤元素含量的相关系数，光谱特征变换后土壤铜(Cu)、锌(Zn)、锰(Mn)元素分别在波长 2 310、440、2 230 nm 处相关系数最大。

(2) 与传统的阈值法提取敏感波段方法相比，KPCA 方法可以有效降低光谱数据的冗余性，实现光谱数据特征信息的有效提取。将 KPCA 方法与 ELM 模型相结合，构建了 KPCA – ELM 土壤含量估测模型，该组合模型可以有效选择最佳变量子集合，提高了模型预测的稳定性，特征提取后的 ELM 模型决定系数增大、均方根误差变小，估测精度明显提高，说明 KPCA – ELM 模型在土壤重金属含量高光谱估测中具有一定的适用性，是一种高效的土壤元素含量优化估测模型。

(3) 基于野外采集黑土样品和实测高光谱数据进行土壤重金属含量估测，适用于小区域内土壤重金属含量的定量反演，由于卫星遥感影像的光谱信息受到大气、地形、地面植被、土壤粗糙度、水分等多

因素影响,导致利用遥感影像进行大范围土壤重金属含量估算的精度低于室内实测高光谱估测精度,所以针对大范围的土壤重金属含量遥感估测还需进一步开展相关分析和研究。

参 考 文 献

[1] 聂哲,李秀芬,吕家欣,等. 东北典型黑土区表层土壤有机质含量高光谱反演研究[J]. 土壤通报,2019,50(6):1285-1293.
NIE Zhe, LI Xiufen, LÜ Jiaxin, et al. Hyperspectral retrieval of surface soil organic matter content in a typical black soil region of Northeast China[J]. Chinese Journal of Soil Science, 2019,50(6):1285-1293. (in Chinese)

[2] 张明月,张奇标,王璐,等. 东北黑土区土壤铬含量高光谱反演研究[J]. 遥感技术与应用,2019,34(2):313-322.
ZHANG Mingyue, ZHANG Qili, WANG Lu, et al. Research on chromium retrieval of black soil with hyperspectral imagery in Northeast of China[J]. Remote Sensing Technology and Application, 2019,34(2):313-322. (in Chinese)

[3] KEMPER T, SOMMER S. Estimate of heavy metal contamination in soils after a mining accident using reflectance spectroscopy[J]. Environmental Science & Technology, 2002, 36(12):2742-2747.

[4] GMUR S, VOGT D, ZABOWSKI D, et al. Hyperspectral analysis of soil nitrogen, carbon, carbonate, and organic matter using regression trees[J]. Sensors,2012,12(8):10639-10658.

[5] 栾福明,张小雷,熊黑钢,等. 基于不同模型的土壤有机质含量高光谱反演比较分析[J]. 光谱学与光谱分析,2013,33(1):196-200.
LUAN Fuming, ZHANG Xiaolei, XIONG Heigang, et al. Comparative analysis of soil organic matter content based on different hyperspectral inversion models[J]. Spectroscopy and Spectral Analysis, 2013,33(1):196-200. (in Chinese)

[6] 王世东,石朴杰,张合兵,等. 基于高光谱的矿区复垦农田土壤全氮含量反演[J]. 生态学杂志,2019,38(1):291-301.
WANG Shidong, SHI Pujie, ZHANG Hebing, et al. Retrieval of soil nitrogen content in reclaimed farmland of mining area based on hyperspectral imaging[J]. Chinese Journal of Ecology, 2019,38(1):291-301. (in Chinese)

[7] 张智韬,王海峰,KARNIELL Arnon,等. 基于岭回归的土壤含水率高光谱反演研究[J/OL]. 农业机械学报,2018,49(5):240-248.
ZHANG Zhitao, WANG Haifeng, KARNIELL Arnon, et al. Inversion of soil moisture content from hyperspectral based on ridge regression[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(5):240-248. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20180528&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.05.028. (in Chinese)

[8] 于雷,洪永胜,耿雷,等. 基于偏最小二乘回归的土壤有机质含量高光谱估算[J]. 农业工程学报,2015,31(14):103-109.
YU Lei, HONG Yongsheng, GENG Lei, et al. Hyperspectral estimation of soil organic matter content based on partial least squares regression[J]. Transactions of the CSAE, 2015, 31(14):103-109. (in Chinese)

[9] 薛利红,周鼎浩,李颖,等. 不同利用方式下土壤有机质和全磷的可见近红外高光谱反演[J]. 土壤学报,2014,51(5):993-1002.
XUE Lihong, ZHOU Dinghao, LI Ying, et al. Prediction of soil organic matter and total phosphorus with vis-NIR hyperspectral inversion relative to land use[J]. Acta Pedologica Sinica, 2014, 51(5):993-1002. (in Chinese)

[10] 刘焕军,张小康,张新乐. 面向土壤分类的高光谱反射特征参数模型[J]. 遥感学报,2017,21(1):105-114.
LIU Huanjun, ZHANG Xiaokang, ZHANG Xinle, et al. Hyperspectral reflectance characteristics parameter extraction for soil classification model[J]. Journal of Remote Sensing, 2017,21(1):105-114. (in Chinese)

[11] 赵玉玲,杨楠楠,张海霞,等. 基于高光谱的邯郸市土壤重金属统计估算模型研究[J]. 生态环境学报,2020,29(4):819-826.
ZHAO Yuling, YANG Nannan, ZHANG Haixia, et al. Study on the statistical estimation model of soil heavy metals in Handan City based on hyper-spectral[J]. Ecology and Environmental Sciences, 2020,29(4):819-826. (in Chinese)

[12] 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/OL]. 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/OL]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(1):170-179. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20190118&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.01.018. (in Chinese)

[13] 王金凤,王世杰,白晓永,等. 基于高光谱反射率的喀斯特地区土壤重金属锌元素含量反演[J]. 光谱学与光谱分析,2019,39(12):3873-3879.
WANG Jinfeng, WANG Shijie, BAI Xiaoyong, et al. Prediction soil heavy metal zinc based on spectral reflectance in Karst area[J]. Spectroscopy and Spectral Analysis, 2019,39(12):3873-3879. (in Chinese)

[14] 胡嘉蕊,吕震雷. 基于核主成分分析的多输出模型确认方法[J]. 北京航空航天大学学报,2017,43(7):1470-1480.
HU Jiarui, LÜ Zhenzhou. Model validation method with multivariate output based on kernel principal component analysis[J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(7):1470-1480. (in Chinese)

[15] 马玥,姜琦刚,孟治国,等. 基于 RF-GABPSO 混合选择算法的黑土有机质含量估测研究[J]. 光谱学与光谱分析,

- 2018,38(1):181–187.
- MA Yue, JIANG Qigang, MENG Zhiguo, et al. Black soil organic matter content estimation using hybrid selection method based on RF and GABPSO [J]. Spectroscopy and Spectral Analysis, 2018,38(1):181–187. (in Chinese)
- [16] 冯禹,崔宁博,龚道枝,等. 基于极限学习机的参考作物蒸散量预测模型[J]. 农业工程学报,2015,33(增刊1):153–160.
- FENG Yu, CUI Ningbo, GONG Daozhi, et al. Prediction model of reference crop evapotranspiration based on extreme learning machine [J]. Transactions of the CSAE, 2015,33(Supp.1):153–160. (in Chinese)
- [17] 郑茂辉,刘少非,柳娅楠,等. 基于粒子群优化极限学习机的排水管网结构状况评价[J]. 同济大学学报(自然科学版), 2020,48(4):513–516.
- ZHENG Maohui, LIU Shaofei, LIU Yanan, et al. Structural condition assessment of urban drainage pipes based on particle swarm optimization-extreme learning machine [J]. Journal of Tongji University(Natural Science), 2020,48(4):513–516. (in Chinese)
- [18] 国婷婷,殷廷家,杨正伟,等. 基于 WPT-IAF-ELM 的小麦储存年限电子舌检测分析[J/OL]. 农业机械学报,2019,50(增刊):404–410.
- GUO Tingting, YIN Tingjia, YANG Zhengwei, et al. Detection and analysis of wheat storage year using electronic tongue based on WPT-IAF-ELM[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(Supp.):404–410. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2019s062&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.S0.062. (in Chinese)
- [19] 倪超,李振业,张雄,等. 基于短波近红外高光谱和深度学习的籽棉地膜分选算法[J/OL]. 农业机械学报,2019,50(12):170–179.
- NI Chao, LI Zhenye, ZHANG Xiong, et al. Sorting algorithm in seed cotton based on near-infrared hyperspectral image and deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(12):170–179. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20191219&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.12.019. (in Chinese)
- [20] 张森,孔盼,李雁华,等. 基于极限学习机的土壤硝态氮预测模型研究[J/OL]. 农业机械学报,2016,47(6):93–99.
- ZHANG Miao, KONG Pan, LI Yanhua, et al. Prediction model of soil NO₃-N concentration based on extreme learning machine[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016,47(6):93–99. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160612&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.06.012. (in Chinese)
- [21] 王昱皓,武建文,马速良,等. 基于核主成分分析-SoftMax 的高压断路器机械故障诊断技术研究[J]. 电工技术学报, 2020,35(增刊1):267–276.
- WANG Yuhao, WU Jianwen, MA Suliang, et al. Fault diagnosis research of high voltage circuit breaker based on kernel principal component analysis and SoftMax[J]. Transactions of China Electrotechnical Society, 2020,35(Supp.1):267–276. (in Chinese)
- [22] 陈永良,林楠,李学斌. 求解大样本核主成分分析模型的 Lanczos 算法[J]. 吉林大学学报(地球科学版),2010,40(1):222–226.
- CHEN Yongliang, LIN Nan, LI Xuebin. Lanczos algorithm for kernel principle component analysis on large scale samples [J]. Journal of Jilin University(Earth Science Edition), 2010,40(1):222–226. (in Chinese)
- [23] 郑超英,叶贝鸽,刘萍,等. 一种基于核主成分分析的驾驶疲劳状态预测方法[J]. 南昌大学学报(工学版),2019,43(2):182–186.
- ZHENG Chaoying, YE Beige, LIU Ping, et al. A method for predicting driving fatigue state based on kernel principal component analysis [J]. Journal of Nanchang University(Engineering & Technology), 2019,43(2):182–186. (in Chinese)
- [24] 蔡亮红,丁建丽. 基于变量优选和 ELM 算法的土壤含水量预测研究[J]. 光谱学与光谱分析,2018,38(7):2209–2214.
- CAI Lianghong, DING Jianli. Prediction of soil water content based on variable preferred and extreme learning machine algorithm[J]. Spectroscopy and Spectral Analysis, 2018,38(7):2209–2214. (in Chinese)
- [25] 董浩,李明星,张淑清,等. 基于核主成分分析和极限学习机的短期电力负荷预测[J]. 电子测量与仪器学报,2018,32(1):188–193.
- DONG Hao, LI Mingxing, ZHANG Shuqing, et al. Short-term power load forecasting based on kernel principal component analysis and extreme learning machine [J]. Journal of Electronic Measurement and Instrumentation, 2018,32(1):188–193. (in Chinese)