

doi:10.3799/dqkx.2015.115

# 基于粒子群优化支持向量机的矿区土壤有机质含量高光谱反演

谭琨<sup>1</sup>, 张倩倩<sup>1</sup>, 曹茜<sup>1</sup>, 杜培军<sup>2\*</sup>

1. 中国矿业大学江苏省资源环境信息工程重点实验室, 江苏徐州 221116

2. 南京大学卫星测绘技术与应用国家测绘地理信息局重点实验室, 江苏南京 210023

**摘要:**为了监测复垦矿区土壤的有机质含量,综合利用光谱分析、统计学习理论与方法以及智能优化理论与方法,研究了矿区复垦土壤有机质含量与土壤光谱之间的关系,在此基础上建立了土壤有机质含量高光谱反演模型,实现土壤有机质含量定量检测。首先对原始土壤光谱数据进行预处理,然后进行相关性分析,提取450 nm、500 nm、650 nm、770 nm、1 460 nm和2 140 nm作为特征波段,最后利用多元线性回归(multiple linear regression, MLR)、偏最小乘回归(partial least squares regression, PLSR)和粒子群优化支持向量机回归(particle swarm optimization support vector machine regression, PSO-SVM)方法建立了土壤有机质含量的高光谱定量反演模型,并对模型进行验证。3种模型的验证结果如下:MLR、PLSR和PSO-SVM模型的 $R^2$ 分别为0.79、0.83和0.85, RMSE分别为5.26、4.93和4.76。实验结果表明,无论从模型的稳定性还是预测能力上,PSO-SVM都要优于其他两个模型。

**关键词:**土壤有机质;高光谱;遥感;粒子群优化支持向量机;粒子群算法。

中图分类号: X87

文章编号: 1000-2383(2015)08-1339-07

收稿日期: 2015-04-15

## Hyperspectral Retrieval Model of Soil Organic Matter Content Based on Particle Swarm Optimization-Support Vector Machines

Tan Kun<sup>1</sup>, Zhang Qianqian<sup>1</sup>, Cao Qian<sup>1</sup>, Du Peijun<sup>2\*</sup>

1. Jiangsu Key laboratory of Resources and Environment Information Engineering, China University of Mining and Technology, Xuzhou 221116, China

2. Key Laboratory for Satellite Mapping Technology and Applications of State Administration of Surveying, Mapping and Geoinformation, Nanjing University, Nanjing 210023, China

**Abstract:** To monitor the soil organic matter in the reclamation area of coal mines, the relationship between soil organic matter content and soil spectra in the reclamation area of coal mines was studied, and a quantitative retrieval model was established and validated in order to implement the organic matter content detection in this paper. After the preprocessing of the original spectral, the correlation of the organic matter content and reflectance spectra was analyzed, and 450 nm, 500 nm, 650 nm, 770 nm, 1 460 nm and 2 140 nm wavelength were extracted as feature bands. Using the multiple linear regression (MLR), partial least squares regression (PLSR) and particle swarm optimization support vector machine regression (PSO-SVM) methods, the hyperspectral quantitative retrieval models for soil organic matter content were built. The results show the coefficient of determination ( $R^2$ ) of MLR, PLSR and PSO-SVM were 0.79, 0.83 and 0.85 respectively, and the root mean square error of prediction (RMSEP) were 5.26, 4.93 and 4.76 respectively. The results demonstrate that the stability and predictive ability of PSO-SVM

**基金项目:**国家自然科学基金项目(Nos.41471356,41402293);卫星测绘技术与应用测绘地理信息局重点实验室项目(No.KLAMTA-201410);国家高技术研究发展计划(863计划)项目(Nos.2008AA121100,2012AA12A308)。

**作者简介:**谭琨(1981—),男,博士,主要从事高光谱遥感、环境遥感和模式识别研究.E-mail: tankun@cumt.edu.cn

\* 通讯作者:杜培军,E-mail: dupjrs@126.com

**引用格式:**谭琨,张倩倩,曹茜,等,2015.基于粒子群优化支持向量机的矿区土壤有机质含量高光谱反演.地球科学——中国地质大学学报,40(8):1339-1345.

model are better than those of the MLR and PLSR model.

**Key words:** soil organic matter; hyperspectral; remote sensing; PSO-SVM; particle swarm optimization algorithm.

## 0 引言

土壤有机质(soil organic matter,SOM)是土壤肥力的重要物质基础之一,不仅能够提供农作物所需养分,还对土壤结构的形成和理化性状的改善有重要作用。传统的实验室化验分析方法由于其耗资、费时、费力等缺点已不能满足现代精细农业发展的需求,而高光谱技术的发展为监测土壤有机质含量提供了更为精确和详细的信息,并使得这一过程变得更加简单、快捷和方便,为土壤评价与理化性质的监测提供了强有力的工具。国内外学者已经利用高光谱技术对土壤中的矿物成分、水分、有机质等进行了定量鉴别等研究,并取得较好的研究成果(Hummel *et al.*, 2001; Liu *et al.*, 2002; Dematté *et al.*, 2006; Ren *et al.*, 2009; 刘焕军等, 2010)。其中,利用高光谱反射率数据进行土壤有机质含量反演取得了许多研究成果,如贺军亮等(2007)对土壤样品高光谱反射率数据进行倒数、导数、对数、标准化比值变换等处理,实验结果表明有机质诊断指数对土壤有机质含量的估算精度较高。宋福明等(2013)建立了不同的土壤有机质高光谱反演模型,结果发现不同模型的精度亦不相同,人工神经网络集成模型精度>单个人工神经网络模型精度>多元逐步回归模型。

利用高光谱数据成功反演土壤有机质含量的关键在于选择有效的数学模型。多元线性回归、主成分回归分析以及偏最小二乘回归等算法建立模型被广泛应用于土壤组分含量的反演工作中(徐永明等, 2006; 刘焕军等, 2007; 卢艳丽等, 2008)。此外,支持向量机和神经网络等建模方法也受到越来越多地关注(郑立华等, 2008; 沈润平等, 2009; 郑立华等, 2010)。

本研究将利用多元线性回归(multiple linear regression,MLR)、偏最小二乘回归(partial least squared regression,PLSR)和基于粒子群优化算法的支持向量机(particle swarm optimization-support vector machines,PSO-SVM)3种方法建立土壤有机质含量高光谱定量反演模型,分别将从平滑(smoothed,S)光谱数据以及它的3种变换光谱一阶导数(first derivative,FD)、标准正态变换(standard normal variate,SNV)和连续统去除(continuum remova,CR)中提取的光谱特征作为模型的输入,并对模型进行验证和精度比较,以确定最佳反演模型。

## 1 研究区域与预处理方案

### 1.1 研究区域与样本采集

实验的研究区域位于江苏省徐州市西北方向的铜山县柳新乡境内。该区由于受采矿活动的影响,土地塌陷现象较为严重,土地复垦工作已于2000年开始进行,复垦后的土地主要用于农业种植。本研究的实验场主要位于东至307国道,西至柳岩公路,南至柳新矿北侧,北至苏北堤河的区域内,总面积为7.033 3 km<sup>2</sup>。在研究区内选取3块小麦地(根据复垦的多样性选取),用S形采样的方法在每块地中均匀选取10个样点,共30个样本,分别用自封袋装好,并做好标记带回。将带回的土壤样本分作两份,一份送至化学实验室对其有机质的含量进行检测,检测统计结果如表1所示;一份送至室内光谱暗室进行土壤光谱反射率的测量。

### 1.2 光谱测量与预处理

土壤光谱测量实验在暗室中进行,采用美国ASD(Ampltical Spectra Devices)公司生产的FieldSpec3地物光谱仪测量土壤样本的光谱反射率数据,其波长范围为350~2 500 nm。在350~1 000 nm和1 000~2 500 nm区间采样间隔分别为1.4 nm和2 nm,光谱分辨率分别为3 nm和10 nm;光谱重采样间隔为1 nm,输出波段数为2 150个。光谱测量过程中每一个土壤样本采集10次光谱反射率,去除异常光谱曲线后取平均值作为该样本的光谱反射率,以保证光谱测量的准确性。土壤样本的原始光谱曲线如图1所示。

土壤光谱在采集的过程中不可避免的会受到随机因素的影响,采集到的光谱信息除了包含样本自身有用信息外,还包含了其他无关的噪音信息,因此对光谱曲线进行数据预处理在光谱分析研究中非常必要。褚小立等(2004)常采用数据预处理的方法(如数据平滑、光谱微分技术、多元散射校正、标准正态变量变换、连续统去除以及倒数和对数变换)消除因

表1 土壤有机质含量检测统计结果

Table 1 The statistical results of the SOM

	最大值 (g/kg)	最小值 (g/kg)	平均值 (g/kg)	标准差 (g/kg)
有机质	53.00	8.50	29.53	12.64

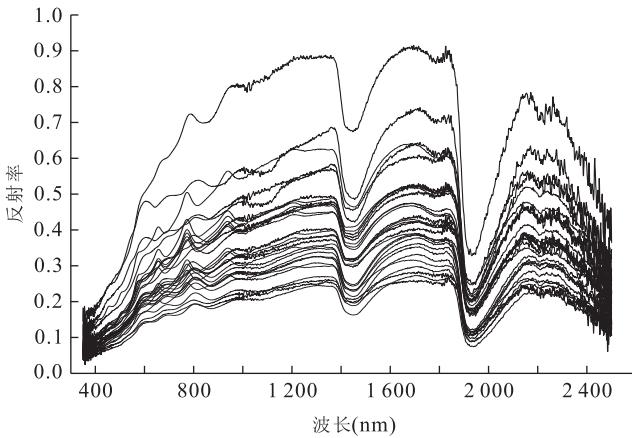


图1 土壤样本光谱反射率曲线

Fig.1 The spectral reflectance curves of the soil samples

为各随机因素影响而产生的噪音.本研究首先对原始光谱进行平滑处理,并在此基础上进行一阶导数变换、标准正态变量变换以及连续统去除变换处理以满足实验要求.

## 2 反演方法与模型验证

### 2.1 多元线性回归(MLR)

多元线性回归是研究多个自变量  $X(x_1, x_2, \dots, x_p)$  与一个因变量  $Y$  之间的线性关系的方法.其数学结构模型为:

$$y = b_0 + \sum_{i=1}^p b_i x_i, \quad (1)$$

式中:  $b_i$  表示回归系数;  $b_0$  表示随机误差;  $p$  表示自变量个数.

本研究以土壤有机质含量作为因变量,平滑光谱反射率及其变换形式中提取的光谱特征作为自变量,建立土壤有机质含量高光谱预测模型.

### 2.2 偏最小二乘回归(PLSR)

偏最小二乘是由欧洲经济计量学家 Herman et al.(1985)于 19 世纪 80 年代首次提出的,它是对多元线性回归模型的一种改进,是一种多对多线性回归建模的方法,在建模过程中集中了主成分分析、典型相关性分析和线性回归分析方法的特点.由于 PLSR 方法的巨大应用前景,这一方法得到了越来越多人的关注.本研究采用偏最小二乘回归模型中的单因变量对多自变量的回归方法(Svensson et al., 2002; Hair et al., 2012).

### 2.3 粒子群优化—支持向量机回归(PSO-SVM)

统计学习理论是由 Vapnik 建立的一种专门研

究小样本情况下机器学习规律的理论,支持向量机是在这一理论基础上发展而来的一种新的机器学习方法.支持向量机通过结构风险最小化原则来提高泛化能力,在保证最小化样本的同时缩小了模型泛化误差的上界,在很大的程度上解决了机器学习中存在的一些问题(Smola and Schölkopf, 2004).

粒子群优化算法(Kennedy, 2010)是近年来发展的一种新的基于群体智能的优化算法,用粒子群算法优化 SVM 的结构参数,可以快速收敛寻得最优解,提高 SVM 的学习能力和诊断效率(左磊等, 2010).在粒子群算法中,可以把所有的优化问题的解想象为  $D$  维搜索空间上的一个点,而这个点就是“粒子”.通过目标函数来评估当前粒子所处位置的好坏,得到相应的适应度值.在种群中粒子的随机初始化形成后,会按照某种方式进行迭代,直到终止条件符合需要,从而寻得最优解,这就是所谓的粒子群优化搜索.

假设  $X_i = (x_{i1}, x_{i2}, L, x_{iD})$  为粒子  $i$  的当前位置,  $V_i = (v_{i1}, v_{i2}, L, v_{iD})$  为粒子  $i$  的当前速度,则粒子经历的最好位置记作  $p_i = (p_{i1}, p_{i2}, L, p_{iD})$ ,也称作  $p_{best}$ ,群体中所有粒子经历的最好位置记作  $p_g$ ,称为  $g_{best}$ .其速度和位置的更新方程如下:

$$v_{id}^{t+1} = w^t v_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t), \quad (2)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}, \quad (3)$$

式中,  $i$  代表第  $i$  个粒子,  $d$  代表粒子的第  $d$  维,  $t$  代表第  $t$  次迭代,  $w$  为惯性权重,  $c_1$  和  $c_2$  为加速度常数,  $r_1$  与  $r_2$  为  $[0, 1]$  上均匀分布的随机函数.

基于 PSO 算法的 SVM 参数选择的具体步骤如下:

(1) 设置待优化的核参数  $\sigma$  和正则化参数  $C$  的取值范围,以及其他初始化参数.

(2) 在核参数  $\sigma$  和正则化参数  $C$  的取值范围随机初始化一群粒子. 初始化每个粒子的位置信息和速度信息,然后将每个粒子的历史最优位置  $p_i$  设为当前位置,群体中最好粒子的当前位置设为  $p_g$ .

(3) 计算每个粒子的适应度.

(4) 对每个粒子,若其适应度值优于上一轮的历史最优值,就用当前位置取代历史最优位置,成为新的  $P_i$ .

(5) 对每个粒子,若其适应度值优于上一轮的全局最优适应度值,就用当前位置取代全局最优位置,成为新的  $p_g$ .

(6) 按照公式(2)和公式(3)对粒子的速度和位

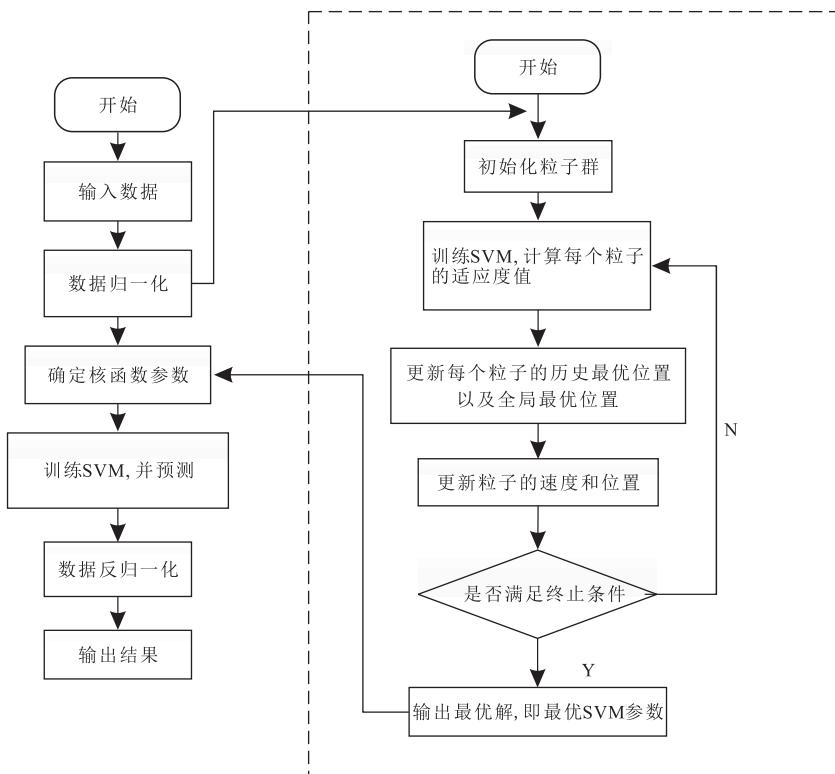


图 2 PSO-SVM 模型建立流程

Fig.2 The flowchart of the PSO-SVM model

置进行更新。

(7) 判断是否满足终止条件, 满足时则停止运算, 否则返回步骤(3)继续迭代。

本研究中模型运算是由 Matlab 编程实现, PSO-SVM 模型的具体运算流程如图 2 所示。

## 2.4 模型验证

从模型的稳定性和预测能力两个方面对模型的精度进行验证。模型的稳定性用决定系数( $R^2$ )衡量; 模型的预测能力用均方根误差(RMSE)衡量。 $R^2$  和 RMSE 计算公式:

$$R^2 = 1 - \frac{\sum (y_m - y_p)^2 / (n - k - 1)}{\sum (y_m - \bar{y})^2 / (n - 1)}, \quad (4)$$

$$RMSE = \sqrt{\frac{\sum (y_m - y_p)^2}{n}}, \quad (5)$$

式中,  $y_m$  为元素含量的测量值;  $\bar{y}$  为测量值的平均值;  $y_p$  为模型的预测值;  $n$  为样本数;  $k$  为自变量个数。

## 3 结果与分析

### 3.1 相关性分析

本研究分别对土壤有机质含量与光谱变换形式

(平滑反射光谱、一阶微分光谱、标准正态变量变换光谱及连续统去除光谱)之间进行了相关性分析, 如图 3 所示。

从图 3 中可以看出, 土壤有机质含量与平滑光谱反射率数据及其变换形式之间存在一定相关性, 与平滑光谱在 1 900 nm 处出现最大正相关, 相关系数为 0.65。与平滑光谱相比, 土壤有机质含量与其他 3 种变换形式的光谱数据的相关性更好, 与一阶微分光谱的相关系数在 870 nm、1 820 nm 和 2 240 nm 波段处正相关系数均高于 0.7, 而在 2 160 nm 处达到最大负相关, 相关系数为 -0.78; 与标准正态变量变换光谱的相关系数在 450 nm 和 500 nm 波段处达到最大正相关, 相关系数分别为 0.86 和 0.90, 在 1 460 nm 波段处最大负相关, 相关系数为 -0.81; 与连续统去除光谱的相关系数在 450 nm 及 500 nm 附近达到 0.87, 波段 1 420 nm、1 460 nm 和 1 880 nm 附近相关系数达到 -0.80。

结合上述的单波段相关性分析与前人研究成果, 笔者选择 6 个与土壤有机质含量相关性较强的波段处的光谱变换后的数据作为输入变量, 具体特征波长选择如表 2 所示。

### 3.2 回归模型的建立

依据单波段相关分析的结果, 本研究以土壤有

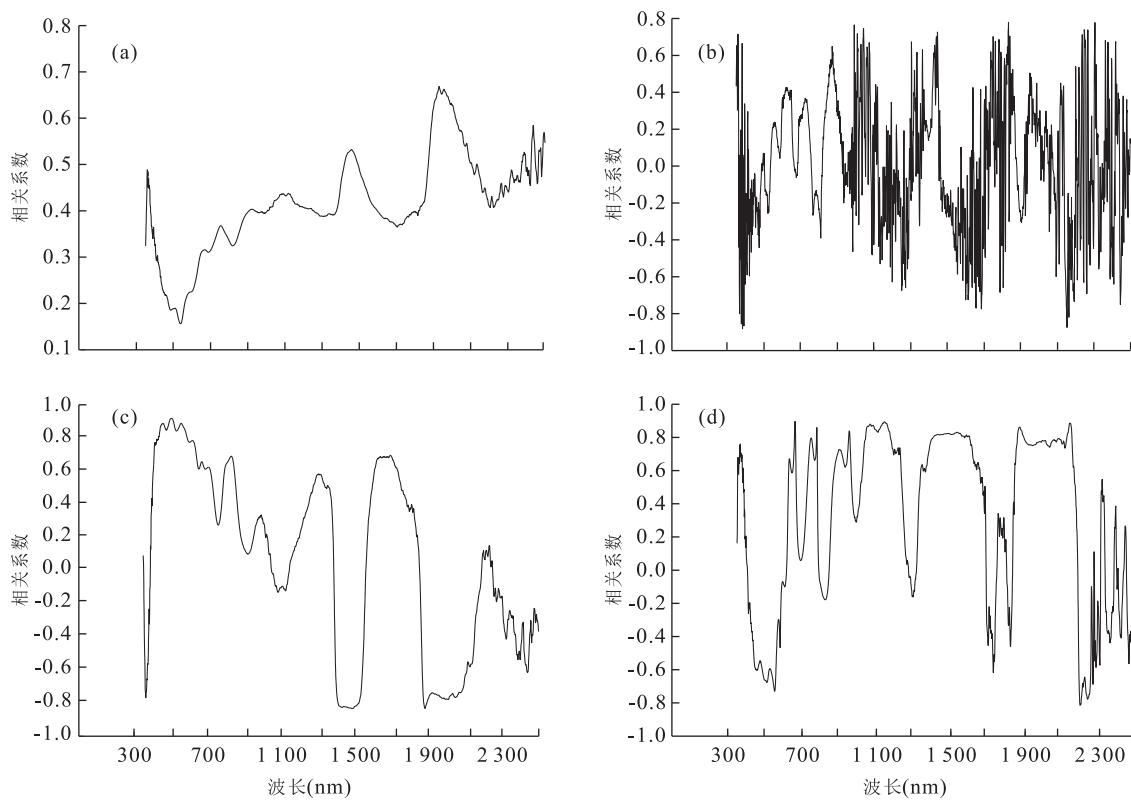


图3 土壤有机质含量与不同变换形式光谱的相关系数随波长变化

Fig.3 The distribution of the correlation coefficients between the SOM concentrations and the different transformed reflectance spectra

a.与平滑光谱;b.与一阶微分光谱;c.与标准正态变量变换光谱;d.与连续统去除光谱

表2 土壤有机质含量定量反演模型的特征光谱

Table 2 The characteristic spectra of the quantitative inversion model of SOM

变量名	波段(nm)	相关系数
SNV( $R$ )	450	0.87
SNV( $R$ )	500	0.90
CR( $R$ )	650	0.83
CR( $R$ )	770	0.87
SNV( $R$ )	1 460	-0.81
CR( $R$ )	2 140	0.87

机质含量作为因变量,选取相关性较高的6个特征波段所对应的土壤光谱数学变换形式作为自变量,建立土壤有机质含量高光谱定量预测模型,其中选取30个土壤样本中的18个样本进行建模,12个样本用于模型检验(图4).实测值与预测值的散点越接近1:1直线,说明反演结果越好.可以看到,除去个别样本偏离1:1直线较远以外,大多数样本都紧密地分布在1:1直线周围,说明反演模型可行.

### 3.3 模型验证

模型的拟合度及稳定性由 $R^2$ 衡量,其值越接

近于1,说明自变量对因变量的解释程度越高,即回归模型的参考价值就越大.由表3中数据统计结果可知,PSO-SVM的决定系数达到最大,为0.85;PLSR的决定系数次之,为0.83;多元线性回归模型的决定系数最小,为0.79.而模型的预测能力是由均方根误差衡量,其值越小,则说明模型的预测结果越准确,精度越高.由表中数据统计结果可知,PSO-SVM模型预测结果的均方根误差最小,为4.76;PLSR略高于PSO-SVM,为4.93;多元线性回归的最大,为5.26.综上所述,3种模型均可用来反演预测土壤有机质含量,但PSO-SVM模型在稳定性和预测能力上都优于其他两种模型,反演效果较好.

## 4 结论

本研究通过对土壤有机质含量与高光谱反射率及其变换形式的相关性分析,从而选定450 nm、500 nm、650 nm、770 nm、1 460 nm和2 140 nm处作为特征波段,这与沙晋明等(2003)和王静等(2005)的研究成果相符合.将这些光谱特征作为土壤有机

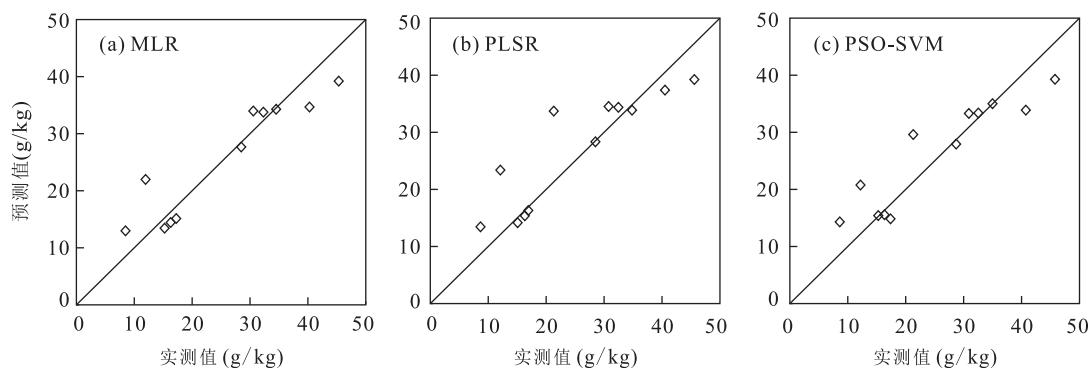


图 4 不同模型有机质实测值与模型预测值之间的比较

Fig.4 A comparison between the measured values and predicted values of the different models

表 3 土壤有机质含量预反演模型的精度统计结果

Table 3 The results of the quantitative inversion models of SOM

模型	$R^2$	RMSE
MLR	0.79	5.26
PLSR	0.83	4.93
PSO-SVM	0.85	4.76

质含量与高光谱定量反演模型的输入自变量,有机质含量作为输出因变量,分别利用 MLR、PLSR 及 PSO-SVM 建立模型。通过对比模型的验证结果可知:不管从决定系数还是均方根误差方面出发,PSO-SVM 模型的稳定性和预测能力都更好( $R^2 = 0.85$ ,  $RMSE = 4.76$ ),PLSR 和 MLR 模型较 PSO-SVM 稍差。但 3 种方法建立的模型都具有一定的反演精度( $R^2 \geq 0.79$ ),说明特征波段的选择较合理,PSO-SVM 模型可以较好地应用于土壤有机质含量的定量反演工作中。

## References

- Chu, X.L., Yuan, H.F., Lu, W.Z., 2004. Progress and Application of Spectral Data Pretreatment and Wavelength Selection Methods in NIR Analytical Technique. *Progress in Chemistry*, 16(4): 528—542 (in Chinese with English abstract).
- Dematté, J.A.M., Sousa, A.A., Alves, M.C., et al., 2006. Determining Soil Water Status and Other Soil Characteristics by Spectral Proximal Sensing. *Geoderma*, 135: 179—195. doi:10.1016/j.geoderma.2005.12.002
- Hair, J.F., Sarstedt, M., Ringle, C.M., et al., 2012. An Assessment of the Use of Partial Least Squares Structural Equation Modeling in Marketing Research. *Journal of the Academy of Marketing Science*, 40(3): 414—433. doi:10.1007/s11747-011-0261-6
- He, J.L., Jiang, J.J., Zhou, S.L., et al., 2007. The Hyperspectral Characteristics and Retrieval of Soil Organic Matter Content. *Scientia Agricultura Sinica*, 40(3): 638—643 (in Chinese with English abstract).
- Hummel, J. W., Sudduth, K. A., Hollinger, S. E., 2001. Soil Moisture and Organic Matter Prediction of Surface and Subsurface Soils Using an Nir Soil Sensor. *Computers and Electronics in Agriculture*, 32(2): 149—165. doi:10.1016/S0168-1699(01)00163-6
- Kennedy, J., 2010. Particle Swarm Optimization. Springer, New York, 760—766.
- Liu, H.J., Zhang, B., Zhao, J., et al., 2007. Spectral Models for Prediction of Organic Matter in Black Soil. *Acta Petrologica Sinica*, 44(1): 27—32 (in Chinese with English abstract).
- Liu, H.J., Zhang, X.L., Zheng, S.F., et al., 2010. Black Soil Organic Matter Predicting Model Based on Field Hyperspectral Reflectance. *Spectroscopy and Spectral Analysis*, 30(12): 3355—3358 (in Chinese with English abstract).
- Liu, W.D., Baret, F., Gu, X.F., et al., 2002. Relating Soil Surface Moisture to Reflectance. *Remote Sensing of Environment*, 81(2—3): 238—246. doi:10.1016/S0034-4257(01)00347-9
- Lu, Y.L., Bai, Y.L., Yang, L.P., et al., 2008. Application of Hyperspectral Data for Soil Organic Matter Estimation Based on Principle Components Regression Analysis. *Plant Nutrition and Fertilizer Science*, 14(6): 1076—1082 (in Chinese with English abstract).
- Luan, F.M., Zhang, X.L., Xiong, H.G., et al., 2013. Comparative Analysis of Soil Organic Matter Content Based on Different Hyperspectral Inversion Models. *Spectroscopy and Spectral Analysis*, 33(1): 196—200 (in Chinese with English abstract).
- Ren, H.Y., Zhuang, D.F., Singh, A., et al., 2009. Estimation

- of As and Cu Contamination in Agricultural Soils around a Mining Area by Reflectance Spectroscopy: A Case Study. *Pedosphere*, 19(6): 719–726. doi: 10.1016/S1002-0160(09)60167-3
- Sha, J.M., Chen, P.C., Lin, C.S., 2003. Characteristics Analysis of Soil Spectrum Response Resulted from Organic Material. *Research of Soil and Water Conservation*, 10(2): 21–24 (in Chinese with English abstract).
- Shen, R.P., Ding, G.X., Wei, G.S., et al., 2009. Retrieval of Soil Organic Matter Content from Hyper-Spectrum Based on ANN. *Acta Petrologica Sinica*, 46(3): 391–397 (in Chinese with English abstract).
- Smola, A.J., Schölkopf, B., 2004. A Tutorial on Support Vector Regression. *Statistics and Computing*, 14(3): 199–222.
- Svensson, O., Kourt, T., Macgregor, J.F., 2002. An Investigation of Orthogonal Signal Correction Algorithms and Their Characteristics. *Journal of Chemometrics*, 16(4): 176–188. doi: 10.1002/cem.700
- Wang, J., He, T., Li, Y.H., 2005. Studying on Extraction Methods for Land Quality Information Based on Hyperspectral Data. *Journal of Remote Sensing*, 9(4): 438–445 (in Chinese with English abstract).
- Wold, H., 1985. Partial Least Squares. *Encyclopedia of Statistical Sciences*. John Wiley & Sons, Inc. USA, 9. doi: 10.1002/0471667196.ess1914.pub2
- Xu, Y.M., Zhong, L.Q., Wang, L., et al., 2006. Model for Estimating Soil Nutrient Elements Based on High Resolution Reflectance Spectra. *Acta Petrologica Sinica*, 43(5): 709–716 (in Chinese with English abstract).
- Zheng, L.H., Li, M.Z., An, X.F., et al., 2010. Forecasting Soil Parameters Based on NIR and SVM. *Transactions of the CSAE*, 26(Suppl.2): 81–87 (in Chinese with English abstract).
- Zheng, L.H., Li, M.Z., Pan, L., et al., 2008. Estimation of Soil Organic Matter and Soil Total Nitrogen Based on NIR Spectroscopy and BP Neural Network. *Spectroscopy and Spectral Analysis*, 28(5): 1160–1164 (in Chinese with English abstract).
- Zuo, L., Hou, L.G., Zhang, W., et al., 2010. Analog Circuit Fault Diagnosis Based on Partical Swarm Optimization Support Vector Machine. *Systems Engineering and Electronics*, 32(7): 1553–1556 (in Chinese with English abstract).

## 附中文参考文献

- 褚小立,袁洪福,陆婉珍,2004.近红外分析中光谱预处理及波长选择方法进展与应用.化学进展,16(4):528–542.
- 贺军亮,蒋建军,周生路,等,2007.土壤有机质含量的高光谱特性及其反演.中国农业科学,40(3):638–643.
- 刘焕军,张柏,赵军,等,2007.黑土有机质含量高光谱模型研究.土壤学报,44(1):27–32.
- 刘焕军,张新乐,郑树峰,等,2010.黑土有机质含量野外高光谱预测模型.光谱学与光谱分析,30(12):3355–3358.
- 卢艳丽,自由路,杨俐萍,等,2008.基于主成分回归分析的土壤有机质高光谱预测与模型验证.植物营养与肥料学报,14(6):1076–1082.
- 栾福明,张小雷,熊黑钢,等,2013.基于不同模型的土壤有机质含量高光谱反演比较分析.光谱学与光谱分析,33(1):196–200.
- 沙晋明,陈鹏程,陈松林,2003.土壤有机质光谱响应特性研究.水土保持研究,10(2):21–24.
- 沈润平,丁国香,魏国栓,等,2009.基于人工神经网络的土壤有机质含量高光谱反演.土壤学报,46(3):391–397.
- 王静,何挺,李玉环,2005.基于高光谱遥感技术的土地质量信息挖掘研究.遥感学报,9(4):438–445.
- 徐永明,蔺启忠,王璐,等,2006.基于高分辨率反射光谱的土壤营养元素估算模型.土壤学报,43(5):709–716.
- 郑立华,李民赞,安晓飞,等,2010.基于近红外光谱和支持向量机的土壤参数预测.农业工程学报,26(增刊2): 81–87.
- 郑立华,李民赞,潘委,等,2008.基于近红外光谱技术的土壤参数BP神经网络预测.光谱学与光谱分析,28(5): 1160–1164.
- 左磊,侯立刚,张旺,等,2010.基于粒子群支持向量机的模拟电路故障诊断.系统工程与电子技术,32(7): 1553–1556.