中国生态农业学报(中英文)
Chinese Journal of Eco-Agriculture
中文核心期刊
中国科技核心期刊
中国精品科技期刊
百种中国杰出学术期刊
中国科学引文数据库源刊

基于BP神经网络的不同人为干扰强度下盐渍土SO 24-定量分析

田安红， 付承彪， 熊黑钢， 赵俊三

引用本文:
田安红, 付承彪, 熊黑钢, 等. 基于BP神经网络的不同人为干扰强度下盐渍土SO 24-定量分析[J]. 中国生态农业学报(中英文), 2020, 28(2): 296-304.

在线阅读 View online: https://doi.org/10.13930/j.cnki.cjea.190700

您可能感兴趣的其他文章

Articles you may be interested in

艾比湖流域不同土地覆盖类型土壤养分高光谱反演模型研究

Hyper-spectral retrieval of soil nutrient content of various land-cover types in Ebinur Lake Basin

中国生态农业学报. 2016, 24(11): 1555-1564 https://doi.org/10.13930/j.cnki.cjea.160547

基于光谱变换的低温胁迫下冬小麦叶绿素含量估测研究

Using spectral transformation processes to estimate chlorophyll content of winter wheat under low temperature stress

中国生态农业学报. 2017, 25(9): 1351-1359 https://doi.org/10.13930/j.cnki.cjea.170134

基于波段深度分析和BP神经网络的水稻色素含量高光谱估算

Hyperspectral estimation of rice pigment content based on band depth analysis and BP neural network

中国生态农业学报. 2017, 25(8): 1224-1235 https://doi.org/10.13930/j.cnki.cjea.170112

BP神经网络算法在河西绿洲玉米生产碳排放评估中的应用及算法有效性研究

Application and validity of BP neural networks on prediction of carbon emissions from corn production in Hexi Oasis

中国生态农业学报. 2018, 26(8): 1100-1106 https://doi.org/10.13930/j.cnki.cjea.180084

基于BP神经网络的农田大气氨浓度预测

Prediction of atmospheric ammonia concentration in farmlands using BP neural network

中国生态农业学报(中英文). 2019, 27(4): 519-528 https://doi.org/10.13930/j.cnki.cjea.181057

DOI: 10.13930/j.cnki.cjea.190700

田安红, 付承彪, 熊黑钢, 赵俊三. 基于 BP 神经网络的不同人为干扰强度下盐渍土 SO_4^{2-} 定量分析[J]. 中国生态农业学报(中英文), 2020, 28(2): 296−304

TIAN A H, FU C B, XIONG H G, ZHAO J S. Quantitative analysis of SO_4^{2-} in saline soil under areas disturbed and undisturbed by human using BP Neural Network[J]. Chinese Journal of Eco-Agriculture, 2020, 28(2): 296−304

基于 BP 神经网络的不同人为干扰强度下盐渍土SO_4^{2-}定量分析*

田安红[1,2], 付承彪[1**], 熊黑钢[3,4], 赵俊三[2]

(1. 曲靖师范学院信息工程学院 曲靖 655011; 2. 昆明理工大学国土资源工程学院 昆明 650093;
3. 北京联合大学应用文理学院 北京 100083; 4. 新疆大学资源与环境科学学院 乌鲁木齐 830046)

摘 要: SO_4^{2-}是盐渍土阴离子中的主要离子, 但目前针对不同人为干扰区域土壤中 SO_4^{2-}反演研究却鲜有报道。土壤高光谱与土壤某元素间的关系表现为非线性, 传统线性偏最小二乘模型(PLSR)对土壤元素的反演精度有限。本文以新疆昌吉回族自治州境内不同人为干扰区域的盐渍化土壤为研究对象, 以土壤的野外高光谱和 SO_4^{2-}含量为数据源, 对原始(R)和对数(LogR)变换后的高光谱分别进行 0 阶、一阶和二阶微分预处理, 选择通过 0.05 显著性水平的波段为敏感波段, 将敏感波段对应的高光谱反射率作为非线性 BP 神经网络模型的输入变量, 并设定 BP 的隐藏节点为 300, 学习速率为 0.01, 最大迭代次数为 1 000, 训练函数为 trainscg。从 SO_4^{2-}的真实值与预测值的散点图、拟合效果图和 BP 训练过程 3 个方面, 定量分析无人为干扰(A 区)和有人为干扰(B 区)土壤 SO_4^{2-}含量, 并与 PLSR 对比预测精度。仿真显示, A 区二阶微分后的 BP 预测精度优于一阶微分, 而 B 区一阶微分后的 BP 预测精度优于二阶微分。且不论在 A 区还是 B 区, LogR 光谱变换的反演精度均优于 R。最佳 BP 模型的相对预测性能(RPD)、决定系数(R^2)、均方根误差(RMSE)和迭代次数, 在 A 区分别为 3.309、0.906、0.253 和 8 次, 在 B 区分别为 2.234、0.844、0.786 和 45 次, 表明 BP 对 A 区 SO_4^{2-}的预测能力非常强(RPD>2.5), 对 B 区 SO_4^{2-}的预测能力较强(RPD 为 2.0~2.5)。而在 A 区和 B 区两种光谱变换的一阶和二阶微分中, PLSR 的 RPD 值均在 1.4 与 1.8 之间, 其预测性能一般; 在 B 区的 0 阶微分中, PLSR 的 RPD 值均小于 1.0, 其不能对 SO_4^{2-}进行预测。因此, BP 模型能对不同人为干扰区域的 SO_4^{2-}进行有效的定量分析。

关键词: 盐渍土; 人为干扰区域; SO_4^{2-}含量; BP 神经网络模型; 光谱变换

中图分类号: S151.9 开放科学码(资源服务)标识码(OSID):

Quantitative analysis of SO_4^{2-} in saline soil under areas disturbed and undisturbed by human using BP Neural Network*

TIAN Anhong[1,2], FU Chengbiao[1**], XIONG Heigang[3,4], ZHAO Junsan[2]

(1. College of Information Engineering, Qujing Normal University, Qujing 655011, China; 2. Faculty of Land Resource Engineering, Kunming University of Science and Technology, Kunming 650093, China; 3. College of Applied Arts and Science, Beijing Union University, Beijing 100083, China; 4. College of Resource and Environment Sciences, Xinjiang University, Urumqi 830046, China)

* 国家自然科学基金项目(41901065, 41671198, 41761081)资助

** 通信作者: 付承彪, 主要从事遥感与地理信息系统的研究。E-mail: fucb305@163.com
田安红, 主要从事干旱区盐渍土的高光谱研究。E-mail: tianfucb@163.com

收稿日期: 2019-09-26 接受日期: 2019-12-10

* This study was supported by the National Natural Science Foundation of China (41901065, 41671198, 41761081).
** Corresponding author, E-mail: fucb305@163.com
Received Sep. 26, 2019; accepted Dec. 10, 2019

Abstract: SO_4^{2-} is one of the main ions in saline soil, but the inversion of SO_4^{2-} ion in soils under different levels of human disturbance has rarely been reported. Moreover, the relationship between soil hyperspectral and soil elements is nonlinear, and the traditional linear partial least squares model (PLSR) has limited inversion accuracy for soil elements. In order to quantitatively analyzed soil SO_4^{2-} content in saline soil, this study selected the saline soils in areas undisturbed and human-disturbed in Changji Hui Autonomous Prefecture of Xinjiang, to predict SO_4^{2-} contents based on soil hyperspectral by using BP Neural Network. The original (R) and logarithmic transformed (LogR) hyperspectral were subjected as 0-order, first-order and second-order differential preprocessing, respectively. The hyperspectral reflectivity corresponding to the sensitive band was taken as the input variable of the nonlinear BP neural network model, and the hidden node, learning rate and maximum number of iterations of BP were set as 300, 0.01, and 1 000. The training function was trainscg. The SO_4^{2-} contents of saline soil in undisturbed area (Area A) and human-disturbed area (Area B) were determined by using the scatter plot of measured and predicted SO_4^{2-} contents, the fitting effect map, and the BP training process. The prediction accuracy was tested by comparison with PLSR results. The simulation showed that the BP prediction accuracy after the second-order differentiation in the Area A was better than the first-order differential, while it was opposite for the Area B. The inversion accuracy of LogR spectral transformation was better than R for both Area A and Area B. The relative prediction performance (RPD), determination coefficient (R^2), root mean square error (RMSE) and iteration number of the optimal BP model were 3.309, 0.906, 0.253 and 8 times in the Area A; and 2.234, 0.844, 0.786 and 45 times in the Area B. It indicated that BP predictive ability was strong for SO_4^{2-} content in Area A and Area B. However, for the first- and second-order differentials of spectral in the Area A and Area B, the RPD values of the PLSR were 1.4–1.8, and the prediction performance was normal; in the 0-order differential of the Area B, the RPD of PLSR were all less than 1.0, which could not predict SO_4^{2-} content. Therefore, the BP model can perform effectively quantitative analysis of SO_4^{2-} in different undisturbed or human-disturbed regions.

Keywords: Saline soil; Human-disturbed area; SO_4^{2-} content; BP neural network model; Spectral transformation

自然界的土壤会因人类的各种干扰而产生一定的变异[1]。目前，针对土壤元素的高光谱反演主要对象集中到受人类干扰的土壤，少有针对不同人为干扰区域土壤元素的反演报道。并且，已有报道的主要预测对象为土壤水分、盐分、氮、磷、速效磷、钾、速效钾、有机质等[2-4]。目前，针对土壤 SO_4^{2-} 含量的高光谱反演研究却鲜有报道。然而，SO_4^{2-} 是土壤盐渍化过程中的主要阴离子，土壤盐渍化是全世界干旱半干旱地区农业生产面临的严重生态环境问题之一[5-7]，它不仅制约农业的可持续发展，还破坏生态环境系统，造成农作物减产、生态失衡问题出现[8-10]。新疆是中国重要的粮食储备基地[11-13]，但其农业生产一直受到土壤盐渍化的制约。因此，及时准确探测 SO_4^{2-} 含量对于掌握新疆盐渍土信息及制定盐渍土改良政策提供一定的依据。

传统对土壤元素的反演模型经常采用线性的偏最小二乘模型(PLSR)，例如，夏芳等[14]以浙江省 36 个县市的农田土壤为研究对象，分析有机质与 8 种重金属的相关性，并采用 PLSR 预测 8 种重金属的含量，仿真结果表明 PLSR 对重金属 Ni 和 Cr 的预测效果较好，其相对预测性能(RPD)值为 1.8~2.0，而剩余 6 种重金属预测模型的 RPD 值均为 1.0~1.4。王文俊等[15]以山西的褐土为研究对象，利用 PLSR 对 20 种高光谱变换后的预处理方法进行建模估算总氮含量，仿真结果表明一阶导数预处理后建模能得到更好的预测结果，且最佳的预处理方法为平均光谱曲线与标准差曲线的乘积，其次为平均光谱曲线与平均光谱曲线的一阶导数、与标准差曲线的乘积，PLSR 模型能对总氮进行有效的预测。然而，土壤高光谱与土壤某元素间的关系表现为非线性，传统线性 PLSR 对土壤元素的反演精度有限，因此需要探索非线性的预测方法。

BP 神经网络模型主要是利用误差的反向传播来实现，其在分析非线性问题时表现出很强的优势，理论上可以逼近任意的非线性函数[16-20]。如刘焕军等[21]以黑龙江省的黑土为研究对象，结合遥感影像和 DEM 数据，利用 BP 神经网络反演土壤有机质含量。仿真结果表明，基于 785~899 nm 波段的单期遥感影像所建立的模型精度和稳定性较高，基于 1 570~1 650 nm 波段的两期遥感影像所建立的模型精度和稳定性更高。因此，本论文选择新疆昌吉回族自治州境内不同人为干扰区域的盐渍化土壤为研究对象，采用 BP 神经网络模型，定量分析不同人为干扰区域土壤 SO_4^{2-} 含量，为精确监测土壤盐渍化提供参考。

1　材料与方法

1.1　土壤样本采集

研究区位于新疆维吾尔自治区昌吉回族自治州境内，87°44′~88°46′E，43°29′~45°45′N，距乌鲁木齐约 70 km。该区域土壤盐渍化严重，土壤表层的盐分

含量为 5.34~44.45 g·kg^{-1} [1]，夏季非常炎热，降水稀少，蒸发强烈，年蒸发量高达 2 000 mm。

研究区有一条长 15.30 km 的水渠，水渠一侧紧临新疆建设兵团 102 团，土壤受人为干扰较严重，为经过土壤翻耕和种植的人工育苗林地。而水渠另一侧因水渠相隔的阻断，基本无人为干扰，土壤保持原生状态，分布有盐爪爪(*Kalidium foliatum*)、猪毛菜(*Salsola collina*)、梭梭(*Haloxylon ammodendron*)等耐盐植物。因此，本研究把水渠两侧分别定义为无人为干扰区域(A 区)和人为干扰区域(B 区)。于 2017 年 5 月 9—23 日采集研究区域 0~20 cm 土层土壤样本。A 区布设采样点 25 个，B 区布设采样点 30 个，如图 1 所示。样本带回实验室经风干、剔除植物和杂质、研磨过筛后，送到中国科学院新疆生态与地理研究所进行土壤样本 SO_4^{2-} 含量测定[22]。

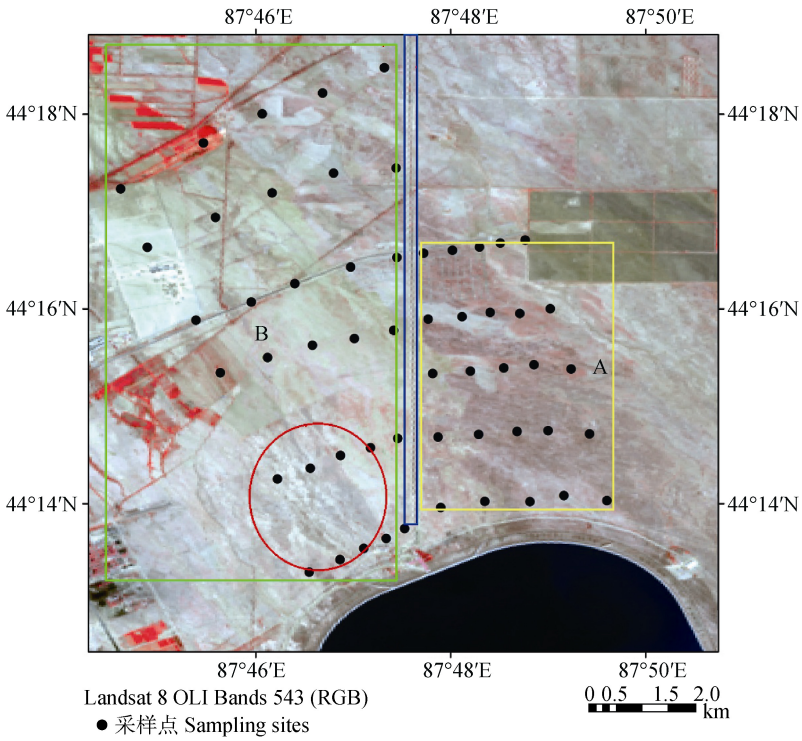

图 1 无人为干扰区**(A)**和人为干扰区**(B)**盐渍土采样点示意图

Fig. 1 Sampling points of saline soils in the undisturbed area (A) and the human-disturbed area (B)

蓝色方框为水渠位置，红色圆圈为农场位置，黄色方框为无人为干扰区(A 区)，绿色方框为人为干扰区(B 区)。The blue box is the location of the canal, the red circle is the location of the farm, the yellow box is the undisturbed area (area A), and the green box is the human disturbing area (area B).

1.2 野外高光谱测量

55 个样本点的野外高光谱采用 FieldSpec®3 Hi- Res 高精度地物光谱仪测量，该仪器的波段范围 300~2 500 nm。350~1 000 nm 波段的采样间隔为 1.4 nm，1 000~2 500 nm 波段的采样间隔为 1 nm。野外测量时选择当地时间 13:00—15:00，且晴朗无风的天气进行。每次测量之前用白板进行光谱校正处理，每个土壤样本点采用梅花桩采样法于 5 个方向重复采集 10 次高光谱，测定高度为距离土壤表面 15 cm。计算平均值为该样点的原始高光谱数据。同时，因边缘波段(350~390 nm 和 2 401~2 500 nm)信噪比低及存在水分吸收带(1 355~1 410 nm 和 1 820~1 942 nm)的干扰，删除这些波段范围的高光谱数据。

1.3 建立 BP 神经网络模型

BP 神经网络模型主要利用误差的反向传播实现，一般为 3 层架构：输入层、隐藏层和输出层。本研究利用 Matlab2019a 软件编程建立 BP 神经网络模型，预测不同研究区域土壤 SO_4^{2-} 含量。BP 神经网络的迭代次数为 1 000，隐藏层节点数为 300，隐藏层的训练函数为 trainscg，学习速率为 0.01，期望误差为 0.000 001。60%的样本作为训练集，剩余的样本作为测试集。输入层是土壤测量的高光谱值，输出层是土壤中 SO_4^{2-} 的含量。

1.4 模型精度评价方法

采用 BP 神经网络模型和偏最小二乘(PLSR)模型预测盐渍土 SO_4^{2-} 含量。模型精度采用决定系数 R^2、均方根误差 RMSE 和相对预测性能 RPD 衡量[23]。好的预测

模型具有较高的 RPD 和 R^2 值, 较小的 RMSE 值。用 RPD 评价模型的预测性能, 当 RPD 值> 2.5、2.0~2.5、1.8~2.0、1.4~1.8、1.0~1.4、<1.0 时, 分别代表模型的预测能力非常强、很好、好、一般、差、不可预测[24-25]。

2　结果与分析

2.1　研究区盐渍土 4 种主要阴离子含量统计

根据土壤 SO_4^{2-} 和 Cl^-含量比例可知, 盐渍土的含盐类型主要有 4 大类[26], 即硫酸盐型、氯化物-硫酸盐型、硫酸盐-氯化物型和氯化物型。因此, SO_4^{2-} 和 Cl^-是土壤盐渍化的重要离子。研究区盐渍土 4 种主要阴离子的描述特性如表 1 所示。在 A 区, SO_4^{2-} 平均含量为 5.104, 远大于 CO_3^{2-}、HCO_3^-和 Cl^-的平均含量, 其占比高达 79.372%。在 B 区, SO_4^{2-}平均含量为 4.291, 大于 Cl^-平均含量, 远大于 CO_3^{2-}和 HCO_3^-平均含量, 其占比高达 57.025%, 且 Cl^-的占比为 40.942%。表 1 说明, A 区的主要阴离子为 SO_4^{2-}, 但 B 区的主要阴离子为 SO_4^{2-}和 Cl^-, 这是因为 B 区土壤被翻耕、犁地、开垦, 且受到人类活动影响较大, 土壤盐渍化类型更为复杂。

表 1　无人为干扰区和人为干扰区盐渍土 4 种阴离子含量描述性统计

Table 1　Descriptive statistics of four anions of saline soil in the undisturbed area and the human-disturbed area

阴离子 Anion	无人为干扰区 Undisturbed area					人为干扰区 Human-disturbed area				
	最小值 Min. value ($g\cdot kg^{-1}$)	最大值 Max. value ($g\cdot kg^{-1}$)	标准差 Standard deviation ($g\cdot kg^{-1}$)	均值 Mean ($g\cdot kg^{-1}$)	比例 Proportion (%)	最小值 Min. value ($g\cdot kg^{-1}$)	最大值 Max. value ($g\cdot kg^{-1}$)	标准差 Standard deviation ($g\cdot kg^{-1}$)	均值 Mean ($g\cdot kg^{-1}$)	比例 Proportion (%)
CO_3^{2-}	0.000	0.098	0.019	0.013	0.196	0.000	0.114	0.025	0.014	0.190
HCO_3^-	0.116	0.233	0.026	0.147	2.288	0.033	0.166	0.024	0.139	1.843
Cl^-	0.077	9.882	2.157	1.167	18.144	0.077	15.646	4.043	3.081	40.942
SO_4^{2-}	1.743	5.734	1.016	5.104	79.372	0.169	5.846	1.729	4.291	57.025

2.2　不同 SO_4^{2-} 含量盐渍土的高光谱曲线特征

为分析不同 SO_4^{2-} 含量的盐渍土高光谱曲线特性, 在 A 区和 B 区分别选择 8 个土壤样本, 其高光谱曲线特征如图 2 所示。A 区土壤样本中, SO_4^{2-} 含量为 5.171 $g\cdot kg^{-1}$ 的样本高光谱反射率值最大, 而 SO_4^{2-} 含量为 5.621 $g\cdot kg^{-1}$ 的样本高光谱反射率值最小; B 区的土壤样本中, 高光谱反射率的最大值和最小值分别对应的 SO_4^{2-} 含量为 5.396 $g\cdot kg^{-1}$和 5.115 $g\cdot kg^{-1}$。因此, 不同 SO_4^{2-} 含量与高光谱曲线之间为非线性关系, 因此需要采用非线性方法来建模。

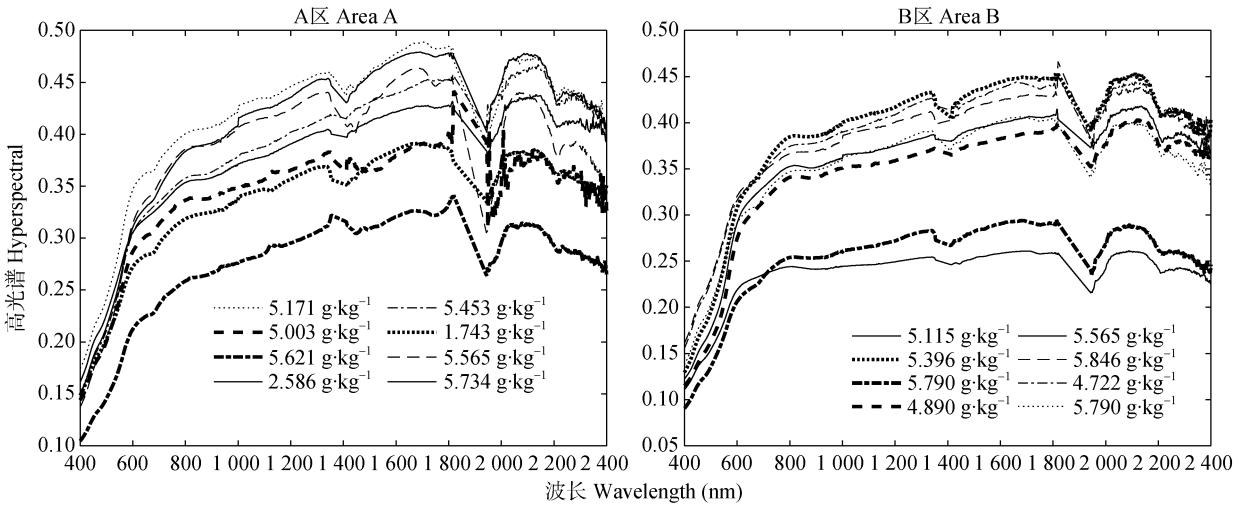

图 2　无人为干扰区(A 区)和人为干扰区(B 区)不同 SO_4^{2-} 含量盐渍土壤样本的高光谱曲线图

Fig. 2　Hyperspectral curves of saline soil samples with different SO_4^{2-} contents in the undisturbed area (Area A) and the human-disturbed area (Area B)

2.3　不同人为干扰区盐渍土 SO_4^{2-} 含量反演特征波段的选择

因土壤高光谱数据包含 2 000 多个波长, 波长之间存在高度的冗余性, 当全部波长代入预测模型, 不仅预测精度低, 且数据计算量大。因此进行反演建模之前的特征波段选择是关键。研究区的原始高

光谱和对数变换高光谱与盐渍土 SO_4^{2-} 含量在 0 阶、一阶和二阶处的相关系数如图 3 所示。在 A 区, 0 阶微分在两种光谱变换中均没有任何波段通过 0.05 检验, 而一阶和二阶微分在两种光谱变换中都有部分波段通过 0.05 检验。在 B 区, 0 阶、一阶和二阶微分在两种光谱变换中都有部分波段通过 0.05 检验。图 3 显示, 与 0 阶相比, 一阶和二阶微分后的相关系数曲线波动更为明显, 且高光谱中更多的波峰和波谷信息也表现出来。

因此, 本研究将两种光谱变换在 0 阶、一阶和二阶微分中通过 0.05 检验的波段选择为特征波段, 研究区通过 0.05 显著性检验的波段数量个数如表 2 所示, 特征波段对应的高光谱值作为后续 BP 神经网络模型的输入变量。

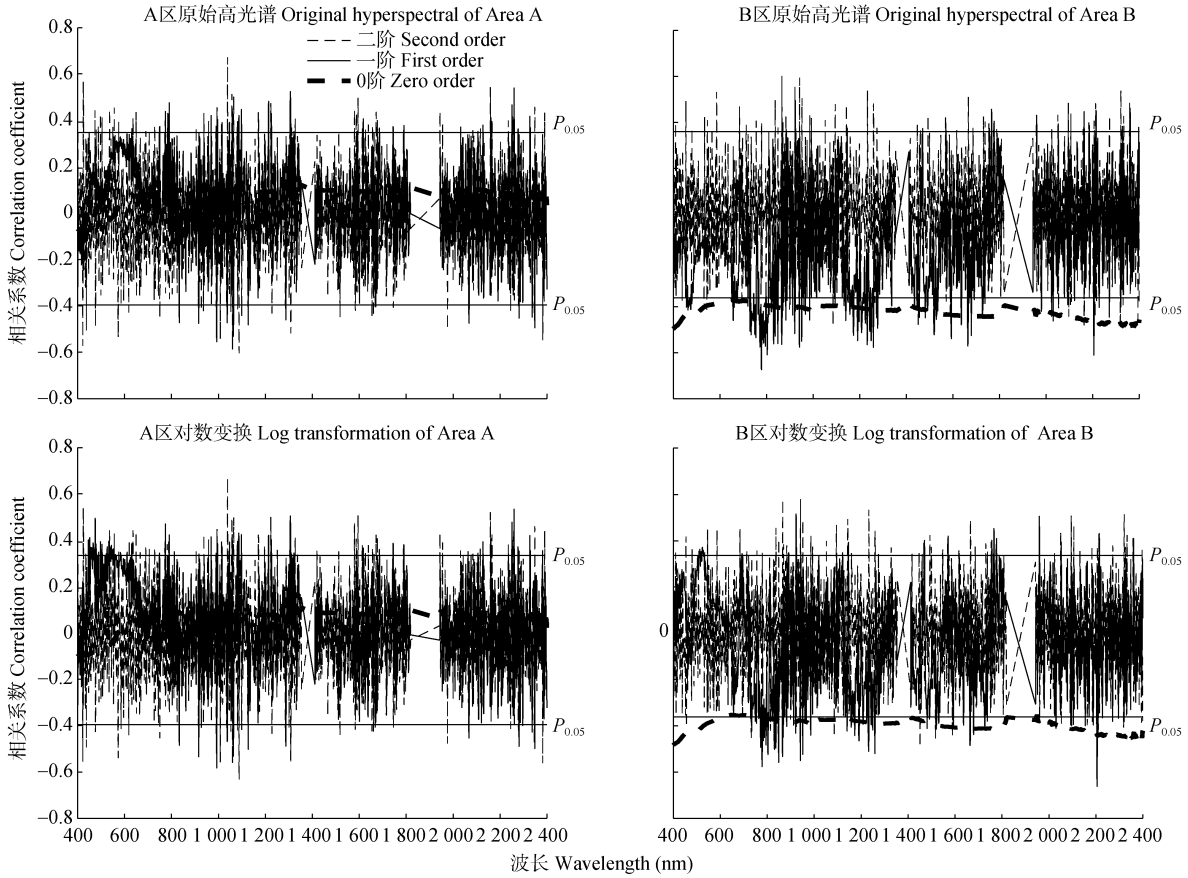

图 3 无人为干扰区(A 区)和人为干扰区(B 区)盐渍土高光谱与 SO_4^{2-} 含量的相关系数

Fig. 3 Correlation coefficients between hyperspectral and SO_4^{2-} content of saline soil in the undisturbed area (Area A) and the human-disturbed area (Area B)

<$|P_{0.05}|$表示显著相关。<$|P_{0.05}|$ indicates significant correlation.

表 2 无人为干扰区和人为干扰区通过 0.05 显著性检验的盐渍土高光谱波段数量个数

Table 2 Number of spectral bands passed the 0.05 significance test for saline soil in the undisturbed area and the human-disturbed area

光谱变换 Spectral transform	无人为干扰区 Undisturbed area	人为干扰区 Human-disturbed area
R 的 0 阶 Zero order of R	0	1 822
R 的一阶 First order of R	38	264
R 的二阶 Second order of R	77	121
LogR 的 0 阶 Zero order of LogR	0	1 659
LogR 的一阶 First order of LogR	39	121
LogR 的二阶 Second order of LogR	74	86

R 表示原始高光谱, LogR 表示对数变换后的光谱。R is the original hyperspectral, LogR is logarithmic transformation of R.

2.4 不同人为干扰区盐渍土 SO_4^{2-} 含量高光谱反演模型

盐渍土 SO_4^{2-} 含量高光谱反演结果如表 3 所示。A 区的最佳反演模型为二阶微分的 LogR 光谱变换对应的 BP 模型, 其 RPD 为 3.309, 表明该模型的预测能力非常强。B 区的最佳反演模型为一阶微分的 LogR 光谱变换对应的 BP 模型, 其 RPD 为 2.234, 表明该模型的预测能力很好。同时, LogR 光谱变换在 A 区的一阶微分对应的 BP 模型, 其 RPD 值>2.5, 表示该模型预测性能非常强, 但低于 LogR 的二阶微分。LogR 光谱变换在 B 区的二阶微分对应的 BP

模型, 其 RPD 值介于 2.0~2.5, 表示该模型预测性能也很好, 但低于 LogR 的一阶微分。另外, R 光谱变换的一阶微分和二阶微分对应的 BP 模型, 在 A 区的 RPD 值均介于 2.0~2.5, 表明这两个模型在 A 区的预测性能也很好; 在 B 区的 RPD 值介于 1.8~2.0, 表明这两个模型在 B 区的预测性能好。R 和 LogR 两种光谱变换在 B 区的 0 阶微分对应的 BP 模型, 其 RPD 值介于 1.0~1.4, 表明这两个模型的预测能力很差。PLSR 模型在 R 和 LogR 两种光谱变换中的一阶微分模型和二阶微分模型中, 其 RPD 值介于 1.4~1.8, 表明这 8 个模型的预测性能一般; PLSR 模型在 B 区的 0 阶微分模型中, 其 RPD 值均小于 1.0, 表明这 2 个模型不能进行预测。

表 3 反演结果表明, 盐渍土 SO_4^{2-} 含量的 BP 模型精度无人为干扰的 A 区高于有人为干扰的 B 区。在 A 区两种光谱变换下的二阶微分预测精度优于一阶微分, 而在 B 区两种光谱变换下的一阶微分预测精度优于二阶微分。且不论在 A 区还是 B 区, LogR 光谱变换的反演精度均优于 R 光谱变换。在有人为干扰的 B 区, 土壤由于人为的种植、翻耕, 破表土壤表层残留的物理结皮、生物结皮、植物残渣, 导致土壤表层失去一定的保护, 在强烈的水分蒸发条件下, 地下水随着毛细血管的运动将深部底层的盐分带入土壤地表, 土壤表层的盐渍化现象相较于无人为干扰的 A 区更为严重, 其盐渍化的类型也更为复杂, 高光谱曲线与土壤阴离子元素间的非线性关系更加复杂和难以预测, 因此出现盐渍土 SO_4^{2-} 含量的 BP 模型精度高于 B 区的情况。

图 3 显示 A 区 R 光谱变换在一阶微分和二阶微分处的最大相关系数分别为 0.554 0 和 0.673 2, A 区 LogR 光谱变换在一阶微分和二阶微分处的最大相关系数分别为 0.583 1 和 0.671 3, B 区 R 光谱变换在一阶微分和二阶微分处的最大相关系数分别为 0.674 4 和 0.603 1, B 区 LogR 光谱变换在一阶微分和二阶微分处的最大相关系数分别为 0.661 5 和 0.578 7。可见 A 区的二阶微分最大相关系数高于一阶微分, 而 B 区的一阶微分最大相关系数高于二阶微分, 因此出现 A 区 SO_4^{2-} 的二阶微分预测精度高于一阶微分, B 区 SO_4^{2-} 的一阶微分精度高于二阶微分的现象。同时, LogR 光谱变换是对原始高光谱 R 的一种非线性变换, 一定程度上能提升高光谱信号间的差异性, 从而提升预测模型的反演精度。

表 3　无人为干扰区和人为干扰区盐渍土 SO_4^{2-} 含量高光谱反演模型的精度

Table 3　Accuracy of hyperspectral inversion models for saline soil SO_4^{2-} contents in the undisturbed area and the human-disturbed area

光谱变换 Spectral transform	模型 Model		无人为干扰区 Undisturbed area			人为干扰区 Human-disturbed area		
			R^2	RMSE	RPD	R^2	RMSE	RPD
原始高光谱(R) Original hyperspectral	BP	0 阶微分 Zero order differential	0.000	0.000	0.000	0.526	1.420	1.135
		一阶微分 First order differential	0.823	0.425	2.372	0.819	1.059	1.967
		二阶微分 Second order differential	0.945	0.367	2.464	0.729	0.946	1.913
	PLSR	0 阶微分 Zero order differential	0.000	0.000	0.000	0.132	1.547	0.824
		一阶微分 First order differential	0.729	0.475	1.490	0.561	1.281	1.482
		二阶微分 Second order differential	0.585	0.765	1.507	0.608	1.079	1.414
对数变换(LogR) Logarithmic transformation	BP	0 阶微分 Zero order differential	0.000	0.000	0.000	0.560	1.333	1.257
		一阶微分 First order differential	0.911	0.380	3.080	0.844	0.786	2.234
		二阶微分 Second order differential	0.906	0.253	3.309	0.766	0.853	2.121
	PLSR	0 阶微分 Zero order differential	0.000	0.000	0.000	0.247	2.325	0.629
		一阶微分 First order differential	0.598	0.723	1.443	0.604	1.257	1.567
		二阶微分 Second order differential	0.734	0.572	1.682	0.667	1.196	1.546

RPD: 相对预测性能。RPD: relative prediction performance.

两个研究区域的最优反演模型的实测值与预测值的散点图如图 4 所示。SO_4^{2-} 含量的真实值与 BP 预测值的拟合效果如图 5 所示, BP 模型的训练过程如图 6 所示。图 4、图 5 和图 6 表明, 当隐藏层的训练函数为 trainscg 时, A 区的 74 个输入变量, 迭代 8 次后满足精度要求, 拟合效果很好, R^2 为 0.905 83, 拟合方程为 y=1.092 6x+0.463 96; B 区的 121 个输入变量, 迭代 45 次后满足精度要求, 拟合效果好, R^2 为 0.843 54, 拟合方程为 y=0.800 28x+1.012 1。并且 A 区和 B 区的 BP 模型预测值均随着 SO_4^{2-} 实测值波动而变化。

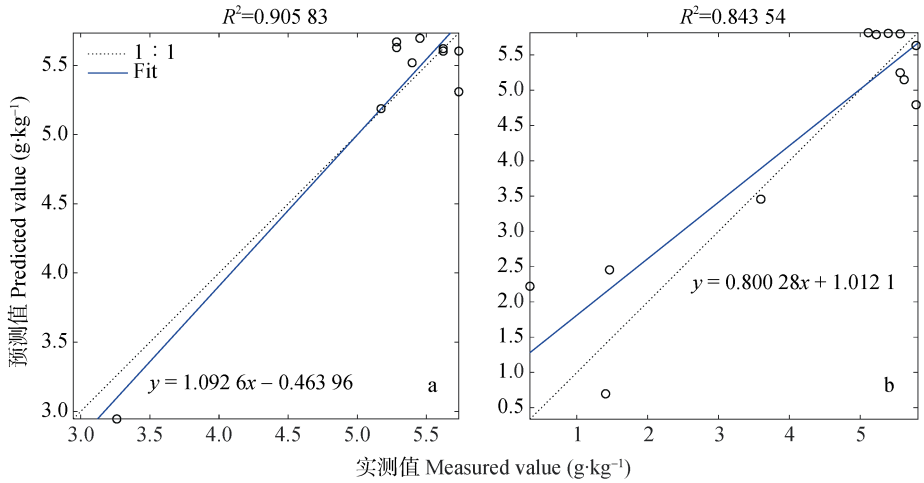

图 4　无人为干扰区(a)和人为干扰区(b)盐渍土 SO_4^{2-} 含量实测值和 BP 模型预测值的散点图

Fig. 4　Scatter plots of the measured and BP model-predicted saline soil SO_4^{2-} contents in the undisturbed (a) and human-disturbed (b) areas

图中预测数据为高光谱对数二阶微分(LogR)的 BP 模型预测值。The predicted values are prediction results of BP model with spectral logarithmic transformation.

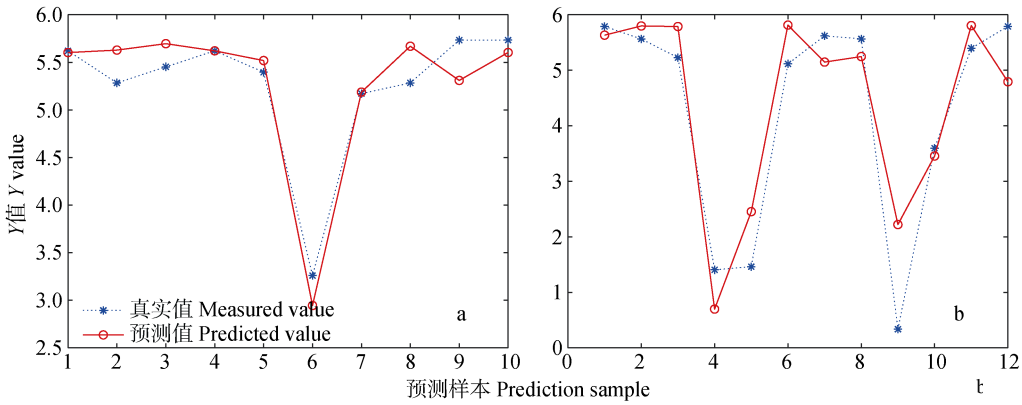

图 5　无人为干扰区(a)和人为干扰区(b)盐渍土 SO_4^{2-} 含量实测值与 BP 模型预测值的拟合效果

Fig. 5　Fitting effects between the measured and BP model-predicted saline soil SO_4^{2-} contents in the undisturbed (a) and human-disturbed (b) areas

图中预测数据为高光谱对数二阶微分(LogR)的 BP 模型预测值。The predicted values are prediction results of BP model with spectral Logarithmic transformation.

3　结论

与 PLSR 模型相比, BP 模型能对有无人为干扰区域下盐渍土的 SO_4^{2-} 含量进行定量分析，这是因为土壤的高光谱是土壤多种组分信息(盐分、有机质、氮磷钾等)和周围环境(土壤类型、植被、气象等)的综合反映, FieldSpec®3 Hi-Res 光谱仪测量的高光谱反射率曲线与某元素之间呈现为非线性关系。本研究结果表明，土壤不同 SO_4^{2-} 含量与高光谱之间为非线性关系。BP 模型能够很好地预测复杂的非线性问题，PLSR 模型则是针对线性问题进行处理，不吻合实际中高光谱数据与土壤元素的非线性关系。所以 BP 模型的预测精度远远高于 PLSR 模型。

以新疆昌吉回族自治州境内不同人为干扰区域的盐渍土为研究对象，采集 55 个土壤样本和野外高光谱数据，利用 BP 模型对选出的特征波段建立 SO_4^{2-} 含量的预测模型，并与传统的 PLSR 线性模型进行对比分析，主要结论如下:

1)在无人为干扰区 SO_4^{2-} 平均含量为 5.104 g·kg^{-1}，远大于 CO_3^{2-}、HCO_3^- 和 Cl^- 平均含量，其占比高达 79.372%。在人为干扰区 SO_4^{2-} 平均含量为 4.291 g·kg^{-1}，大于 Cl^- 平均含量，远大于 CO_3^{2-} 和 HCO_3^- 平均含量，其占比高达 57.025%，且 Cl^- 的占比为 40.942%。

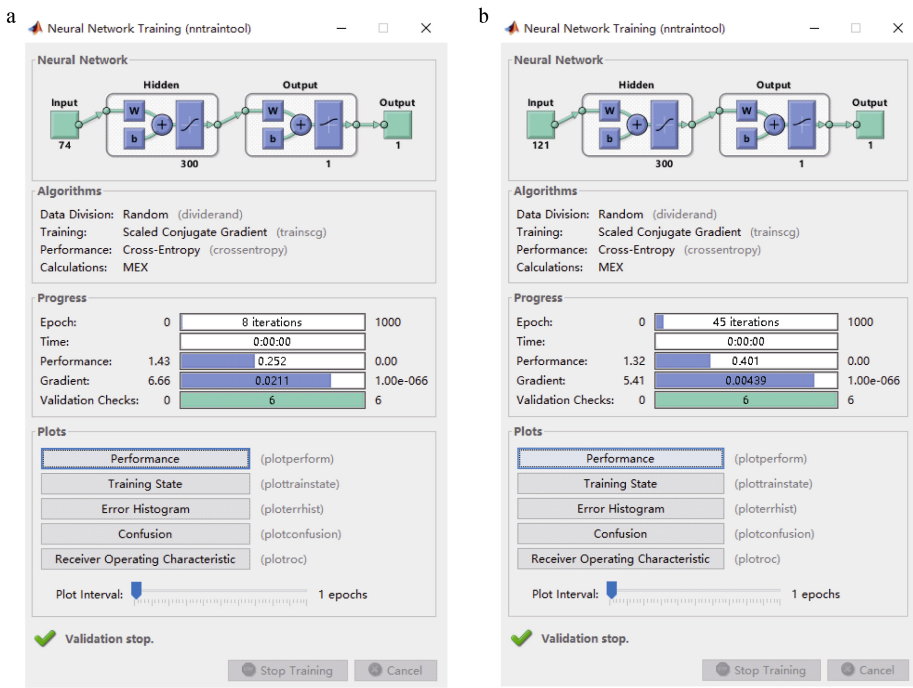

图 6　无人为干扰区(a)和人为干扰区(b)盐渍土 SO_4^{2-} 含量 BP 模型的训练过程

Fig. 6　Training processes of the BP model of saline soil SO_4^{2-} contents in the undisturbed (a) and human-disturbed (b) areas

2)无人为干扰区和人为干扰区土壤样本的高光谱反射率曲线表明，盐渍土 SO_4^{2-} 含量与高光谱曲线之间为非线性关系。

3)统计相关系数在 0 阶、一阶和二阶微分中通过 0.05 检验的波段数量，R 变换在无人为干扰区分别为 0 个、38 个和 77 个，在人为干扰区分别为 0 个、39 个和 74 个；LogR 变换在无人为干扰区分别为 1 822 个、264 个和 121 个，在人为干扰区分别为 1 659 个、121 个和 86 个。

4)无人为干扰区的最佳反演模型为二阶微分的 LogR 光谱变换对应的 BP 模型，其 RPD 为 3.309，表明该模型的预测能力非常强。人为干扰区的最佳反演模型为一阶微分的 LogR 光谱变换对应的 BP 模型，其 RPD 为 2.234，表明该模型的预测能力很好。

5)土壤 SO_4^{2-} 的 BP 模型精度无人为干扰高于人为干扰。在无人为干扰区两种光谱变换下的二阶微分预测精度优于一阶微分，而在人为干扰区两种光谱变换下的一阶微分预测精度优于二阶微分的预测精度。且不论有无人为干扰，盐渍土 LogR 光谱变换的反演精度均优于 R 光谱变换。

参考文献 References

[1] 段鹏程，熊黑钢，李荣荣，等. 不同干扰程度的盐渍土与其光谱反射特征定量分析[J]. 光谱学与光谱分析, 2017, 37(2): 571–576
DUAN P C, XIONG H G, LI R R, et al. A quantitative analysis of the reflectance of the saline soil under different disturbance extent[J]. Spectroscopy and Spectral Analysis, 2017, 37(2): 571–576

[2] 高会，陈红艳，刘慧涛，等. 基于高光谱的鲁西北平原土壤有效磷含量快速检测研究[J]. 中国生态农业学报，2013, 21(6): 752–757
GAO H, CHEN H Y, LIU H T, et al. Spontaneous determination of soil available phosphorus using high spectrum in the northwest plain of Shandong Province[J]. Chinese Journal of Eco-Agriculture, 2013, 21(6): 752–757

[3] 张娟娟，余华，乔红波，等. 基于高光谱特征的土壤有机质含量估测研究[J]. 中国生态农业学报, 2012, 20(5): 566–572
ZHANG J J, YU H, QIAO H B, et al. Soil organic matter content estimation based on hyperspectral properties[J]. Chinese Journal of Eco-Agriculture, 2012, 20(5): 566–572

[4] 蔡亮红，丁建丽. 基于高光谱多尺度分解的土壤含水量反演[J]. 激光与光电子学进展, 2018, 55(1): 400–409
CAI L H, DING J L. Inversion of soil moisture content based on hyperspectral multi-scale decomposition[J]. Laser & Optoelectronics Progress, 2018, 55(1): 400–409

[5] MASOUD A A, KOIKE K, ATWIA M G, et al. Mapping soil salinity using spectral mixture analysis of landsat 8 OLI images to identify factors influencing salinization in an arid region[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 83: 101944

[6] LITALIEN A, ZEEB B. Curing the earth: A review of an-

thropogenic soil salinization and plant-based strategies for sustainable mitigation[J]. Science of the Total Environment, 2020, 698: 134235

[7] EL HASINI S, IBEN HALIMA O, EL AZZOUZI M, et al. Organic and inorganic remediation of soils affected by salinity in the Sebkha of Sed El Mesjoune — Marrakech (Morocco)[J]. Soil and Tillage Research, 2019, 193: 153–160

[8] LI N, KANG Y H, LI X B, et al. Response of tall fescue to the reclamation of severely saline coastal soil using treated effluent in Bohai Bay[J]. Agricultural Water Management, 2019, 218: 203–210

[9] SCUDIERO E, SKAGGS T H, CORWIN D L. Comparative regional-scale soil salinity assessment with near-ground apparent electrical conductivity and remote sensing canopy reflectance[J]. Ecological Indicators, 2016, 70: 276–284

[10] LI J G, PU L J, HAN M F, et al. Soil salinization research in China: Advances and prospects[J]. Journal of Geographical Sciences, 2014, 24(5): 943–960

[11] 梁静, 丁建丽, 王敬哲, 等. 基于反射光谱与 Landsat 8 OLI 多光谱数据的艾比湖湿地土壤盐分估算[J]. 土壤学报, 2019, 56(2): 320–330
LIANG J, DING J L, WANG J Z, et al. Quantitative estimation and mapping of soil salinity in the Ebinur lake wetland based on vis-NIR reflectance and landsat 8 OLI data[J]. Acta Pedologica Sinica, 2019, 56(2): 320–330

[12] WANG R S, WAN S Q, SUN J X, et al. Soil salinity, sodicity and cotton yield parameters under different drip irrigation regimes during saline wasteland reclamation[J]. Agricultural Water Management, 2018, 209: 20–31

[13] PENG J, BISWAS A, JIANG Q S, et al. Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China[J]. Geoderma, 2019, 337: 1309–1319

[14] 夏芳, 彭杰, 王乾龙, 等. 基于省域尺度的农田土壤重金属高光谱预测[J]. 红外与毫米波学报, 2015, 34(5): 593–598
XIA F, PENG J, WANG Q L, et al. Prediction of heavy metal content in soil of cultivated land: Hyperspectral technology at provincial scale[J]. Journal of Infrared and Millimeter Waves, 2015, 34(5): 593–598

[15] 王文俊, 王璨, 李志伟, 等. 基于高光谱技术的褐土土壤总氮含量的预测[J]. 山西农业大学学报: 自然科学版, 2018, 38(9): 71–76
WANG W J, WANG C, LI Z W, et al. Prediction of total nitrogen content in brown soil based on hyperspectral technology[J]. Journal of Shanxi Agricultural University: Natural Science Edition, 2018, 38(9): 71–76

[16] LIANG Y J, REN C, WANG H Y, et al. Research on soil moisture inversion method based on GA-BP neural network model[J]. International Journal of Remote Sensing, 2019, 40(5/6): 2087–2103

[17] CUI K, QIN X T. Virtual reality research of the dynamic characteristics of soft soil under metro vibration loads based on BP neural networks[J]. Neural Computing and Applications, 2018, 29(5): 1233–1242

[18] ZHAO H J, SHI S G, JIANG H Z, et al. Calibration of AOTF-based 3D measurement system using multiplane model based on phase fringe and BP neural network[J]. Optics Express, 2017, 25(9): 10413–10433

[19] AO H, LIAO X Y, ZHAO D, et al. Delineation of soil contaminant plumes at a co-contaminated site using BP neural networks and geostatistics[J]. Geoderma, 2019, 354: 113878

[20] GOLHANI K, BALASUNDRAM S K, VADAMALAI G, et al. A review of neural networks in plant disease detection using hyperspectral data[J]. Information Processing in Agriculture, 2018, 5(3): 354–371

[21] 刘焕军, 潘越, 窦欣, 等. 黑土区田块尺度土壤有机质含量遥感反演模型[J]. 农业工程学报, 2018, 34(1): 127–133
LIU H J, PAN Y, DOU X, et al. Soil organic matter content inversion model with remote sensing image in field scale of blacksoil area[J]. Transactions of the CSAE, 2018, 34(1): 127–133

[22] 乔娟峰, 熊黑钢, 王小平, 等. 基于最优模型的荒地土壤有机质含量空间反演[J]. 江苏农业学报, 2018, 34(1): 68–75
QIAO J F, XIONG H G, WANG X P, et al. Spatial inversion of soil organic matter content in wasteland based on optimal model[J]. Jiangsu Journal of Agricultural Sciences, 2018, 34(1): 68–75

[23] BALDOCK J A, HAWKE B, SANDERMAN J, et al. Predicting contents of carbon and its component fractions in Australian soils from diffuse reflectance mid-infrared spectra[J]. Soil Research, 2013, 51(8): 577

[24] 王海峰, 张智韬, Arnon Karnieli, 等. 基于灰度关联-岭回归的荒漠土壤有机质含量高光谱估算[J]. 农业工程学报, 2018, 34(14): 124–131
WANG H F, ZHANG Z T, KARNIELI A, et al. Hyperspectral estimation of desert soil organic matter content based on gray correlation-ridge regression model[J]. Transactions of the CSAE, 2018, 34(14): 124–131

[25] 张秋霞, 张合兵, 张会娟, 等. 粮食主产区耕地土壤重金属高光谱综合反演模型[J]. 农业机械学报, 2017, 48(3): 148–155
ZHANG Q X, ZHANG H B, ZHANG H J, et al. Hybrid inversion model of heavy metals with hyperspectral reflectance in cultivated soils of main grain producing areas[J]. Transactions of the Chinese Society of Agricultural Machinery, 2017, 48(3): 148–155

[26] 田安红, 熊黑钢, 赵俊三, 等. 分数阶微分对盐渍土野外光谱预处理精度提升的机理分析[J]. 光谱学与光谱分析, 2019, 39(8): 2495–2500
TIAN A H, XIONG H G, ZHAO J S, et al. Mechanism improvement for pretreatment accuracy of field spectra of saline soil using fractional differential algorithm[J]. Spectroscopy and Spectral Analysis, 2019, 39(8): 2495–2500