

# 玉米生长铜铅污染信息光谱辨别研究

杨可明 何家乐 李艳茹 吴兵 张建红

(中国矿业大学(北京)地球科学与测绘工程学院,北京 100083)

**摘要:**为辨别农作物所受重金属胁迫种类,以受重金属铜(Cu)、铅(Pb)胁迫的玉米叶片为研究对象,利用ASD地物光谱仪获得叶片高光谱数据,通过分数阶微分(FD)对原始光谱数据进行处理,采用竞争性自适应重加权采样法(CARS)提取特征波段,最后通过多层感知机(MLP)、K-最近邻(KNN)、支持向量机(SVM)3种模型对受胁迫的叶片光谱进行辨别,选择最优的MLP构建的FD-CARS-MLP模型,进行玉米生长铜铅污染信息光谱辨别。结果表明,FD-CARS-MLP模型对于受胁迫叶片光谱辨别能力相较于传统方式有所提高,试验集辨别精度均可达到98%以上,0.1、0.2阶分数阶微分辨别精度可达到99%以上。选取苗期与抽穗期的玉米叶片,对其进行FD-CARS-MLP模型的可行性测试,经验证可得,FD-CARS-MLP模型辨别受重金属胁迫玉米叶片光谱数据的精度更高且更稳定,可为监测谷类作物不同重金属胁迫提供技术与方法。

**关键词:**玉米叶片;高光谱;胁迫辨别;分数阶微分;特征波段

中图分类号:P23 文献标识码:A 文章编号:1000-1298(2023)09-0254-06

OSID:



## Spectral Identification of Copper and Lead Pollution Information during Corn Growth

YANG Keming HE Jiale LI Yanru WU Bing ZHANG Jianhong

(School of Earth Science and Surveying and Mapping Engineering,  
China University of Mining and Technology (Beijing), Beijing 100083, China)

**Abstract:** To identify the types of heavy metal stress on crops, corn leaves under heavy metal stress of copper (Cu) and plumbum (Pb) were selected as the research object. The hyperspectral data of corn leaves were obtained by ASD Field-Spectrometer. The original spectral data were processed by fractional differential (FD), and feature bands were extracted by competitive adaptive reweighted sampling method (CARS). Finally, multi-layer perceptron (MLP), K-nearest neighbor (KNN) and support vector machine (SVM) were used to distinguish the spectra of stressed leaves. The FD-CARS-MLP model constructed by the optimal MLP was selected to distinguish the spectral information of corn growth copper and plumbum pollution. The results showed that the FD-CARS-MLP model was better than the traditional methods in spectral discrimination of stressed leaves. The accuracy of the FD-CARS-MLP model could reach more than 98% in all test sets, and the accuracy of fractional differential discrimination of 0.1 and 0.2 orders could reach more than 99%. Corn leaves at the seedling stage and heading stage were selected for the feasibility test of the FD-CARS-MLP model. It was proved that the FD-CARS-MLP model had higher accuracy and more stability in identifying the spectral data of corn leaves under heavy metal stress, which could provide technology and methods for monitoring different heavy metal stresses of cereal crops.

**Key words:** corn leaf; hyperspectral; stress discrimination; fractional differentiation; characteristic band

## 0 引言

玉米是世界主要的谷类作物,近年来玉米的总

产量仅次于水稻,位居我国第二位<sup>[1]</sup>,玉米已经逐渐成为日常生活中基本的粮食、饲料和生产原料等。因此玉米种植中的健康生长尤为重要,玉米的合理

化种植逐渐成为研究热点<sup>[2]</sup>。如果土壤中的重金属含量超标,就会逐渐被农作物吸收并累积,从而对人体有严重影响<sup>[3~4]</sup>,其中铅(Pb)是重金属污染物毒性较大的一种,能直接伤害人的脑细胞;而铜(Cu)中毒轻者会产生胃肠道黏膜刺激症状,重者甚至会出现肾功能衰竭及尿毒症、休克等<sup>[5~7]</sup>。

农作物的重金属污染监测非常关键,只有正确地识别重金属污染元素的类别,才可以对农作物接下来种植的土壤进行调整<sup>[8~10]</sup>,因此对玉米生长中所受重金属污染的辨别研究显得尤为重要,采用高光谱技术辨别重金属污染逐渐成为了遥感应用热点<sup>[11]</sup>,目前采用高光谱技术进行参量反演的方法比较常见<sup>[12~13]</sup>,但是运用到农作物重金属污染辨别还较少。

高伟等<sup>[14]</sup>建立了CLCDF污染判别特征,对作物中的重金属污染种类进行判别,为重金属胁迫的光谱辨别提供了新的思路;GUO等<sup>[15]</sup>通过基于高光谱的ML模型,确定污染垂直分布的关键因素和判断地下土壤中的金属(类);LI等<sup>[16]</sup>通过构建新的光谱指数,快速识别了土壤重金属污染中的元素,经过验证该模型的通用性和鲁棒性都较好。还有学者采用了特征光谱融合提取<sup>[17~19]</sup>以及深度强化学习<sup>[20~22]</sup>的方法对植被灾害以及污染进行辨别。

上述研究在重金属胁迫辨别方面均取得了较好的结果,但是光谱处理与辨别方法较为繁琐,辨别准确度仍需提高,算法较为复杂,计算量大,不易进行应用,因此寻找一种快速辨别农作物重金属污染的方法变得尤为重要。本文以受不同程度铜铅(Cu、Pb)胁迫的玉米叶片为研究对象,采用ASD光谱仪获取玉米叶片的光谱,经过0.1~1.0阶的分数阶微分(Fractional derivatives, FD)处理后,通过竞争性自适应重加权算法(Competitive adaptative reweighted sampling, CARS)提取光谱的特征光谱,最后通过比较多种辨别模型的性能,最终选择性能最佳的多层次感知机(Multi-layer perceptron, MLP),构建FD-CARS-MLP模型并进行试验,以达到辨别玉米叶片中Cu、Pb污染信息的目的。

## 1 试验

### 1.1 试验材料

以不同梯度重金属元素(Cu、Pb)胁迫的不同时期玉米生长叶片为研究对象,选用玉米品种为中糯1号。共分为两组:重金属元素(Cu、Pb)胁迫试验分别选CuSO<sub>4</sub>·5H<sub>2</sub>O和Pb(NO<sub>3</sub>)<sub>2</sub>溶液作为试剂,胁迫梯度为0、50、100、150、200、300、400、600、800、1 000、1 200 μg/g,胁迫梯度平行试验共3组。试验

期间,保持土壤湿润,空气畅通,保证各盆栽生长环境一致,避免其他因素对试验结果产生影响。

### 1.2 光谱采集

选取ASD FieldSpec 4型便携式地物光谱仪,进行重金属元素(Cu、Pb)胁迫试验苗期、拔节期、抽穗期玉米叶片高光谱数据采集。每次光谱反射率测定前使用标准白板对光谱反射系数进行校准,光纤探头视场角为25°,探头垂直于叶片表面,垂距小于5 cm,每盆玉米叶片光谱测量5次。得到不同重金属(Cu、Pb)胁迫试验的光谱曲线如图1所示。

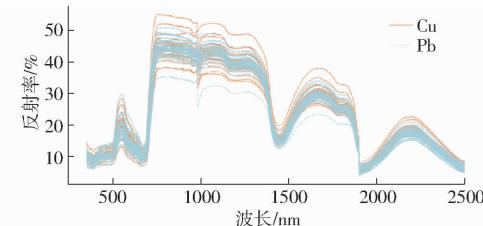


图1 重金属(Cu、Pb)胁迫的光谱曲线

Fig. 1 Spectral curves of heavy metal (Cu and Pb) stress

## 2 基本原理

### 2.1 分数阶微分

分数阶微分的定义形式有很多种,其中主要有Riemann-Liouville、Grünwald-Letnikov、Caputo、Remann-liouville、广义函数等<sup>[23~24]</sup>,本研究选择Grünwald-Letnikov进行光谱数据处理。若设f(λ)为一维的光谱曲线,则分数阶微分定义可表示为

$$\frac{d^q}{d\lambda^q}f(\lambda) \approx f(\lambda) + (-q)f(\lambda-1) + \frac{(-q)(-q+1)}{2}f(\lambda-2) + \dots + \frac{\tau(-q+1)}{n! \tau(-q+n+1)}f(\lambda-n) \quad (1)$$

式中 q——任意阶数 n——波段数  
λ——波段的中心波长

将波长范围按步长h进行等分,[a, t]为波长范围区间,λ ∈ [a, t],因为玉米叶片在光谱采集时,光谱仪光谱重采样间隔为1 nm,因此令h=1,n=t-a。

### 2.2 竞争性自适应重加权采样法

竞争性自适应重加权采样法(CARS)结合了蒙特·卡罗方法(Monte Carlo, MC)和最小偏二乘回归方法(Least squares regression, PLS)对特征变量进行选择<sup>[25~26]</sup>,该算法和达尔文的“适者生存”理念非常相似。CARS采用自适应加权采样(Adaptive reweighted sampling, ARS)的方法,选择PLS中回归系数绝对值占比权重相对较大的波长,形成新的组合形式<sup>[27]</sup>,去掉权重占比较小的特征波

长,以新建的组合为基础重复上述方法,得到 PLS 交互验证均方根误差 (Root mean square error of cross validation, RMSECV) 最小的最优组合,该组合中的剩余波长将被作为原始光谱的特征波段,进行接下来的数据辨别,具体过程如下:

(1) 通过蒙特·卡罗方法,从原数据中随机抽取一部分数据用于模型建立<sup>[28]</sup>,剩余数据将作为 PLS 模型的预测数据(一般建模数据与预测数据的比例为 8:2),采样时 PLS 中的回归系数权重的绝对值计算式为

$$w_i = \frac{|\beta_i|}{\sum_{i=1}^m |\beta_i|} \quad (2)$$

式中  $\beta_i$ —第  $i$  个变量回归系数

$w_i$ —第  $i$  个变量回归系数权重

$m$ —采样剩余变量的数量

(2) 通过指数衰减函数 (Exponentially decreasing function, EDF) 剔除回归系数权重占比绝对值相对较小的波段,第  $i$  次 MC 采样构建 PLS 模型时,通过 EDF 获取保留波段点的占比  $R_i$  为

$$R_i = ue^{-k_i} \quad (3)$$

式中  $u, k_i$ —常数

(3) 每轮采样均从前一轮采样时的数据中,通过自适应加权采样 (ARS) 提取  $R_i$  的  $n$  个波段,进行建模,并经过计算得到 RMSECV。

(4) 经过所有的采样后,CARS 生成了多组待选择的特征波段集合,并且每个集合都有相对应的 RMSECV,最后保留 RMSECV 最小的一组作为所需要的特征波段。

## 2.3 交叉验证

交叉验证又名循环估计,是一种统计学中将数据作为总集合分成多个子集合的过程<sup>[29]</sup>。K-fold 交叉验证即在样本空间中,选择大量数据作为训练样本,剩余数据作为模型的测试样本,并且求出剩余样本的误差、准确度以及其平均值。将样本的误差平方相加,即可得到模型的预测误差。常见的交叉验证方法有简单交叉验证、K-fold 交叉验证和留一验证,本研究选择最常用的 K-fold 交叉验证,在数据辨别之前划分出训练、预测数据。

## 2.4 分类算法

分类是一种通过机器学习 (Machine learning) 的自然语言处理任务,机器学习中的分类算法,是通过训练集来预测其他数据将会属于某个种类的概率。本研究选择的分类算法为多层感知机 (Multi-layer perceptron, MLP)、K-最近邻 (K-nearest neighbors, KNN)、支持向量机 (Support vector machine, SVM),

经过试验最终选择性能最优的 MLP 分类模型作为主辨别方法。

以 MLP 分类模型为例,该模型分为输入层、隐藏层和输出层,其中输入层为数据的不同特征,在本研究中就是光谱不同波段的反射率,即输入层的神经元个数就是光谱的波段数目;隐藏层为 1 层,有 25 个神经元;最后输出层共有 2 个神经元,分别表示铜污染和铅污染信息。

## 3 结果与分析

### 3.1 分数阶微分

分数阶微分处理后的光谱数据和原数据差别较大,它可以放大数据的特征,获取到光谱数据中的更多细节信息,相较于原数据更有利于污染信息的辨别。综合考虑光谱数据量和数据质量,本研究选择以拔节期玉米叶片光谱数据为主,苗期和抽穗期为辅进行辨别,对受重金属 (Cu、Pb) 胁迫生长的玉米叶片高光谱数据进行从原光谱到 1.0 阶的分数阶微分处理(即 0~1.0, 以 0.1 为间隔依次增加),随着微分阶数的不断增加,光谱逐渐产生变化,以 200 μg/g 浓度梯度铜胁迫下的拔节期玉米叶片光谱为例,经过 0.1~1.0 阶分数阶微分的光谱曲线如图 2 所示。

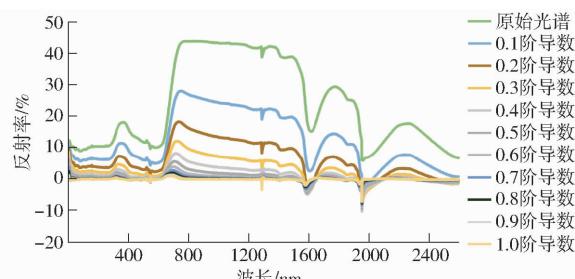


图 2 0.1~1.0 阶分数阶微分的光谱曲线

Fig. 2 Spectral curves of 0.1~1.0 orders fractional differential

### 3.2 CARS 获取特征波段

原数据的波段为 350~2 500 nm,如果直接运用,不仅后续处理数据量庞大,数据处理时间过长,而且特征点过多也会使分类的精度降低。CARS 可以通过计算,直接筛选出回归系数权重占比最大的波段,直接得出原数据的最佳特征波段,该方法相较于传统的主成分分析法 (Principal components analysis, PCA) 等方法更加方便,不用手动调整参数即可直接给出多种特征波段组合以及每一种波段组合的 RMSECV,该均方根误差越小表示该波段组合的性能越好,通过比较每一种波段组合的 RMSECV 即可直接给出最佳特征波段,采用该种方法进行特征提取更加简便智能,而且不会遗漏特征波段组合。

本研究的特征波段提取过程由 Python 编程实现, 对经过分数阶微分后的光谱数据通过 CARS 进行特征数据提取, 从 2 250 个波段中进行自动的特征波段选取。进行胁迫辨别时要求相同波段对应, 本研究对以重金属 (Cu、Pb) 胁迫的光谱数据进行 CARS 计算。接下来以拔节期 Cu、Pb 胁迫光谱数据为例, 结合图 3 进行分析。

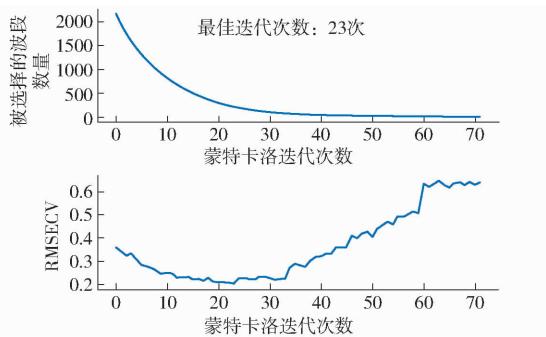


图 3 经过 CARS 计算的拔节期 Cu、Pb 胁迫原数据

Fig. 3 Cu and Pb stressor data at jointing stage after CARS

对于拔节期的重金属 (Cu、Pb) 胁迫光谱数据进行 CARS 计算, 其最佳筛选次数与特征波段数如表 1 所示。

表 1 最佳筛选次数与特征波段数

Tab. 1 Optimal number of screening times and number of characteristic bands

参数	分数阶微分阶数										
	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
最佳迭代次数	23	35	31	27	25	18	16	15	13	12	11
特征波段数	223	69	101	150	148	365	445	491	598	654	728

由图 3 和表 1 可得, 随着迭代次数的增加, 得到的特征光谱数量不断减少, RMSECV 呈现先降低后增加的趋势, 对于重金属 (Cu、Pb) 胁迫光谱数据来说, 随着分数阶微分阶数的不断增加, 最佳特征波段所对应的迭代次数不断减少, 波段数量不断增加。

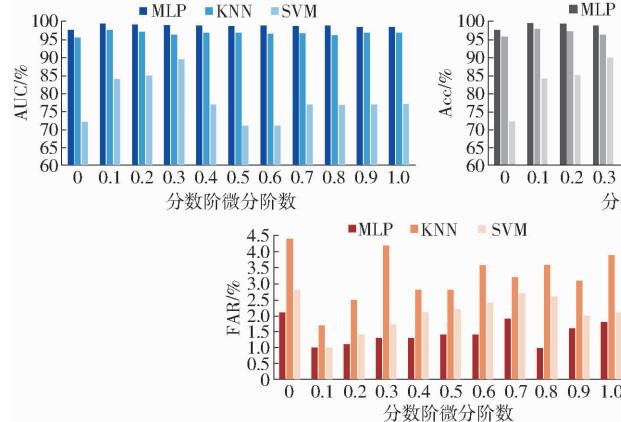


图 4 基于 MLP、KNN、SVM 分类模型的拔节期 Cu、Pb 污染辨别评价指标对比

Fig. 4 Comparision of Cu and Pb identification and evaluation indicators during jointing stage based on MLP, KNN and SVM classification models

### 3.3 依据最佳特征波段的污染辨别

经过分数阶微分和 CASR 处理后, 得到了代表每一组光谱的最佳特征波段, 然后选择不同的分类模型进行胁迫污染辨别, 选取最适合玉米叶片光谱数据的模型, 以达到最好的污染辨别效果。本研究选择的分类算法为 MLP、KNN、SVC。在数据辨别之前先通过 5 折交叉验证 ( $K = 5$ ) 划分出训练数据和预测数据, 以方便后续对所建的模型进行性能评估。基于接收者操作特征曲线 (Receiver operating characteristic curve, ROC), 本研究选择 ROC 曲线下面积 (Area under curve, AUC)、准确率 (Accuracy, Acc)、精确度 (Precision, Pre)、错误接受率 (False acceptance rate, FAR) 以及错误拒绝率 (False rejection rate, FRR) 5 个评价指标, 5 个评价指标均位于 0~100% 之间, 其中 AUC、Acc、Pre 3 个指标数值越接近于 100%, FAR、FRR 2 个指标越接近于 0 表示所建立的模型辨别性能越好。3 种分类模型指标如图 4 所示。

由图 4 可得, 3 个分类模型中, KNN 模型的 AUC、Acc、Pre 3 个指标数值均在 95% 以上, 除原数据以外, 均为 96% 以上; FAR、FRR 均在 4% 以下; MLP 模型的 AUC、Acc、Pre 均在 97% 以上, 除原数据以外, 均为 98% 以上; FAR、FRR 均在 2% 以下, MLP 模型相比于 KNN 模型在 5 个指标数值上均提高 2 个百分点, 性能较好, 对于重金属 (Cu、Pb) 胁迫玉米叶片的辨别能力较好; 而 SVM 明显不适用于本次研究数据的辨别。

本研究的数据量较大, 因此 SVM 并不适用; KNN 分类模型的计算量较大, 特别是当特征变量增多时, 而本试验的特征变量较大, 并且如果样本量不平衡时, 其精度也会有所降低; MLP 分类模型辨别率高且分类速度快, 因此 MLP 综合来看最适合本研究的分类任务。

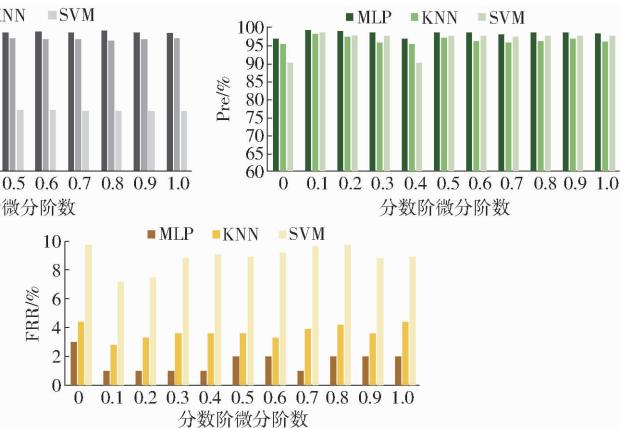


图 4 基于 MLP、KNN、SVM 分类模型的拔节期 Cu、Pb 污染辨别评价指标对比

Fig. 4 Comparision of Cu and Pb identification and evaluation indicators during jointing stage based on MLP, KNN and SVM classification models

选取 MLP 作为数据辨别的方法,对重金属(Cu、Pb)胁迫的光谱数据进行辨别。分析可得,经过分数阶微分的污染信息辨别评价指标高于原数据,并且最佳的阶数为 0.1 和 0.2,随着阶数的增加,辨别准确度有所下降,但是仍高于原始光谱数据。由此可以构建一个新的玉米叶片重金属(Cu、Pb)污染信息高光谱遥感辨别模型——FD-CARS-MLP 模型。

### 3.4 辨别模型验证

为了验证 FD-CARS-MLP 模型的可行性,选择拔节期、抽穗期重金属(Cu、Pb)胁迫的玉米叶片进行验证,分数阶微分选择效果最好的 0.1、0.2 阶进行验证,结果如表 2 所示。

表 2 FD-CARS-MLP 模型验证

Tab. 2 FD-CARS-MLP model validation

类别	阶数	CARS			MLP		
		最佳迭 代次数	波段 数	AUC/ %	Acc/ %	Pre/ %	FAR/ %
拔节期	0.1	32	88	99.8	99.8	99.6	0.1
	0.2	31	106	99.7	99.6	99.8	1.1
抽穗期	0.1	30	115	99.5	99.4	99.7	1.2
	0.2	28	123	99.3	99.1	99.6	1.4

由表 2 可知,运用高光谱数据的分数阶微分处理结果,FD-CARS-MLP 模型对于受胁迫的玉米

叶片 Cu、Pb 污染信息辨别的精度较高且更稳定,为监测谷类作物不同胁迫的重金属污染监测提供了技术与方法。

## 4 结论

(1) 光谱数据经分数阶微分处理后,许多光谱特征被加强,能够获取到更多细节信息,相较于原始光谱数据更有利于污染信息的辨别,试验可得,所有经过分数阶微分处理光谱数据的辨别精度均大于原数据,其中 0.1、0.2 阶的分数阶微分效果最好,数据辨别评估指标 AUC、Acc、Pre 的精度可以达到 99% 以上,FAR、FRR 的精度可以达到 1% 以下。

(2) CARS 相较于传统的特征光谱波段提取方法,可以涵盖每一组特征波段组合,更加全面化,且不用手动调整参数,更加方便快捷,CARS 可以通过算法直接给出最佳的特征波段组合,使特征波段的选择更加智能化。

(3) 经试验证明,FD-CARS-MLP 模型可以有效地对受胁迫的叶片光谱数据进行 Cu、Pb 污染信息辨别,该模型的辨别评估指标 AUC、Acc、Pre 可以高达 98% 以上,FAR、FRR 可以达到 2% 以下。FD-CARS-MLP 模型辨别玉米在生长过程中受重金属胁迫的叶片污染信息效果良好,并且具有较好的可靠性和稳定性。

## 参考文献

- [1] 韩天富,李亚贞,曲潇林,等.中国农田小麦和玉米产量时空演变及驱动因素[J].农业工程学报,2022,38(1):100–108.  
HAN Tianfu, LI Yazhen, QU Xiaolin, et al. Spatio-temporal evolution of wheat and maize yields in China and its driving factors [J]. Transactions of the CSAE, 2022,38(1):100 – 108. (in Chinese)
- [2] 宋红梅,李廷亮,刘洋,等.我国近 20 年主要粮食作物产量、进出口及化肥投入变化特征[J].水土保持学报,2022,37(1):1–8.  
SONG Hongmei, LI Tingliang, LIU Yang, et al. The changing characteristics of main grain crop output, import and export and fertilizer input in our country in recent 20 years[J]. Journal of Soil and Water Conservation, 2022,37(1):1 – 8. (in Chinese)
- [3] 田稳,宗大鹏,方成刚,等.西南典型菜地土壤重金属健康风险和毒性效应[J].中国环境科学,2022,42(10):4901–4908.  
TIAN Wen, ZONG Dapeng, FANG Chenggang, et al. Health risks and toxic effects of heavy metals in typical vegetable soils in Southwest China[J]. China Environmental Science, 2022,42(10):4901 – 4908. (in Chinese)
- [4] SU Haifeng, ZHANG Yanzhao, LU Zichun, et al. A mechanism of microbial sensitivity regulation on interventional remediation by nanozyme manganese oxide in soil heavy metal pollution[J]. Journal of Cleaner Production, 2022,373:133825.
- [5] LIN Tan, ZHENG Qixu, YOU Guoli, et al. Eco-environmental, human health risk assessment of soils and crops heavy metals in the typical black-rock series area in the northern Baba mountains, China[J]. Doklady Earth Sciences, 2022,506(2):839 – 848.
- [6] GEETHA N, SUNILKUMAR C R, BHAVYA G, et al. Warhorses in soil bioremediation: seed bioprimer with PGPF secretome to phytostimulate crop health under heavy metal stress[J]. Environmental Research, 2022,216(1):114498.
- [7] 沈德中,王宏康,罗厚枚,等.铜、镍、铅、锌 4 种重金属对水田土壤藻类的综合效应[J].中国环境科学,1994(4):277–282.  
SHEN Dezhong, WANG Hongkang, LUO Houmei, et al. Comprehensive effects of four heavy metals of copper, nickel, lead and zinc on soil algae in paddy fields[J]. China Environmental Science, 1994(4):277 – 282. (in Chinese)
- [8] 邹鲤岭,杨加庆,程先锋,等.云南东川小江沿岸农田土壤和白菜重金属污染研究[J].西南农业学报,2018,31(4):754–758.  
ZOU Liling, YANG Jiaqing, CHENG Xianfeng, et al. Study on heavy metal pollution of farmland soil and cabbage along Xiaojiang River in Dongchuan, Yunnan[J]. Southwest China Journal of Agricultural Sciences, 2018,31(4):754 – 758. (in Chinese)
- [9] 李俊猛,翟雪东,杨子涵,等.重金属铜胁迫苹果砧木根系的显微拉曼光谱诊断研究[J].光谱学与光谱分析,2022,42(9):2890–2895.  
LI Junmeng, ZHAI Xuedong, YANG Zihan, et al. Micro-Raman spectroscopic diagnosis of apple rootstock rootstocks under

- copper stress [J]. Spectroscopy and Spectral Analysis, 2022, 42(9):2890–2895. (in Chinese)
- [10] 刘娟, 李洋, 张敏, 等. 滇东农田土壤铅污染健康风险评价及基准研究 [J]. 农业工程学报, 2021, 37(1):241–250. LIU Juan, LI Yang, ZHANG Min, et al. Health risk assessment and benchmark study of agricultural soil lead pollution in Eastern Yunnan [J]. Transactions of the CSAE, 2021, 37(1):241–250. (in Chinese)
- [11] KENDLER S, MANO Z, AHARON R, et al. Hyperspectral imaging for chemicals identification: a human-inspired machine learning approach [J]. Scientific Reports, 2022, 12(1):17580.
- [12] BLUMBERG A, SCHODLOK M C. The synergistic use of multi-scale remote sensing data for the identification of hydrothermal alteration patterns in Los Frailes, Spain [J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 114:103034.
- [13] ARIF M, QI Yuancui, DONG Zhi, et al. Rapid retrieval of cadmium and lead content from urban greenbelt zones using hyperspectral characteristic bands [J]. Journal of Cleaner Production, 2022, 374:133922.
- [14] 高伟, 杨可明, 陈改英, 等. 利用叶片光谱的作物铜铅污染判别 [J]. 农业工程学报, 2021, 37(3):173–178. GAO Wei, YANG Keming, CHEN Gaiying, et al. Discrimination of Cu and Pb pollution of crops by using leaf spectrum [J]. Transactions of the CSAE, 2021, 37(3):173–178. (in Chinese)
- [15] GUO Zhaozhu, ZHANG Yunxia, XU Rui, et al. Contamination vertical distribution and key factors identification of metal(loid)s in site soil from an abandoned Pb/Zn smelter using machine learning [J]. The Science of the Total Environment, 2022, 856(P2):159264.
- [16] LI Yanru, YANG Keming, WU Bing, et al. Identification of soil heavy metal pollution by constructing 2D plane using hyperspectral index [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 12(7):666–673.
- [17] LIU Fan, WANG Fang, WANG Xiaoqiao, et al. Rapeseed variety recognition based on hyperspectral feature fusion [J]. Agronomy, 2022, 12(10):2350.
- [18] 郭小燕, 于帅卿, 沈航驰, 等. 基于全局特征提取的农作物病害识别模型 [J]. 农业机械学报, 2022, 53(2):301–307. GUO Xiaoyan, YU Shuaiqing, SHEN Hangchi, et al. Crop disease recognition with global feature extraction [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2):301–307. (in Chinese)
- [19] 于海洋, 谢赛飞, 郭灵辉, 等. 融合光谱和空间特征的土壤重金属含量极端随机树估算 [J]. 农业机械学报, 2022, 53(8):231–239. YU Haiyang, XIE Saifei, GUO Linghui, et al. Extreme random tree estimation of soil heavy metal content based on spectral and spatial characteristics [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8):231–239. (in Chinese)
- [20] 郭文娟, 冯全, 李相周. 基于农作物病害检测与识别的卷积神经网络模型研究进展 [J]. 中国农机化学报, 2022, 43(10):157–166. GUO Wenjuan, FENG Quan, LI Xiangzhou. Research progress of convolutional neural network model based on crop disease detection and identification [J]. Journal of Chinese Agricultural Mechanization, 2022, 43(10):157–166. (in Chinese)
- [21] WANG Youyou, XIONG Feng, ZHANG Yue, et al. Application of hyperspectral imaging assisted with integrated deep learning approaches in identifying geographical origins and predicting nutrient contents of coix seeds [J]. Food Chemistry, 2023(404):134503.
- [22] 李国旭, 耿静, 许选虹, 等. 基于 World View-3 多光谱和关键环境变量的土壤镉含量反演 [J]. 农业工程学报, 2022, 38(12):224–232. LI Guoxu, GENG Jing, XU Xuanhong, et al. Inversion of soil cadmium content based on World View-3 multispectral and key environmental variables [J]. Transactions of the CSAE, 2022, 38(12):224–232. (in Chinese)
- [23] 王瑾杰, 丁建丽, 葛翔宇, 等. 分数阶微分技术在机载高光谱数据估算土壤含水量中的应用 [J]. 光谱学与光谱分析, 2022, 42(11):3560–3567. WANG Jinjie, DING Jianli, GE Xiangyu, et al. Application of fractional differentiation technique in estimating soil moisture content from airborne hyperspectral data [J]. Spectroscopy and Spectral Analysis, 2022, 42(11):3560–3567. (in Chinese)
- [24] ARZU T D, SADIYE N T P. Fourth kind chebyshev wavelet method for the solution of multi-term variable order fractional differential equations [J]. Engineering Computations, 2022, 39(4):241–252.
- [25] 路皓翔, 张静, 李灵巧, 等. 最小角回归结合竞争性自适应重加权采样的近红外光谱波长选择 [J]. 光谱学与光谱分析, 2021, 41(6):1783–1788. LU Haoxiang, ZHANG Jing, LI Lingqiao, et al. Wavelength selection of near-infrared spectroscopy based on minimum angle regression combined with competitive adaptive reweighting sampling [J]. Spectroscopy and Spectral Analysis, 2021, 41(6):1783–1788. (in Chinese)
- [26] 李跑, 周骏, 蒋立文, 等. 窗口竞争性自适应重加权采样策略的近红外特征变量选择方法 [J]. 光谱学与光谱分析, 2019, 39(5):1428–1432. LI Pao, ZHOU Jun, JIANG Liwen, et al. Near infrared feature variable selection method of window competitive adaptive reweighting sampling strategy [J]. Spectroscopy and Spectral Analysis, 2019, 39(5):1428–1432. (in Chinese)
- [27] ZHEN Zhenxia, YANG Jie, WANG Jing, et al. Optimizing rice near-infrared models using fractional order Savitzky-golay derivation (FOSGD) combined with competitive adaptive reweighted sampling (CARS) [J]. Applied Spectroscopy, 2020, 74(4):417–426.
- [28] 谢林江, 洪明坚, 余志荣. 一种结合直接正交信号校正与蒙特卡罗的波长选择方法 [J]. 光谱学与光谱分析, 2022, 42(2):440–445. XIE Linjiang, HONG Mingjian, YU Zhirong. A wavelength selection method combining direct orthogonal signal correction and Monte Carlo [J]. Spectroscopy and Spectral Analysis, 2022, 42(2):440–445. (in Chinese)
- [29] WANG Zhe, ZHOU Hongmin, MA Wu, et al. Land surface albedo estimation and cross validation based on GF-1 WFV data [J]. Atmosphere, 2022, 13(10):1651.