

# 基于注意力机制的土壤重金属污染物高光谱检测深度学习方法

叶 叶

(泰州学院 信息工程学院 云计算大数据实验室, 江苏 泰州 225300)

**摘要:** 高光谱图像和深度学习技术为土壤污染物检测提供了新的方法和工具。本研究旨在探索基于卷积神经网络(CNN)的高光谱土壤污染物检测算法。首先,收集了包含多个波段的高光谱土壤数据集,并进行数据分析和特征提取;然后,设计了一种适应高光谱土壤数据特点的CNN网络架构,提出针对高光谱数据特点的自注意力机制,自动对冗余光谱数据降维,再使用图谱特征融合特征提取结构构建模型;最后,在收集的土壤污染物数据集上验证算法性能。实验结果表明,所提出的方法能够对高光谱数据有效降维,降低数据冗余程度,通过融合图谱特征,在土壤污染物检测方面取得了较好的性能和准确性,对土壤污染物的快速检测有一定实际意义。

**关键词:** 高光谱; 土壤污染; 注意力机制

中图分类号: TP751.2      文献标志码: A      文章编号: 1001-8891(2025)04-0453-06

## A Deep Learning Method for Hyperspectral Detection of Heavy Metal Contaminants in Soil Based on Attention Mechanism

YE Ye

(Cloud Computing Big Data Laboratory of School of Information Engineering, Taizhou University, Taizhou 225300, China)

**Abstract:** Hyperspectral imaging and deep learning techniques provide new methods and tools for detecting soil contaminants. This study explores a convolutional neural network (CNN)-based algorithm for the detection of hyperspectral soil contaminants. First, a hyperspectral soil dataset containing multiple spectral bands was collected, and data analysis and feature extraction were performed. Subsequently, a CNN architecture adapted to the characteristics of hyperspectral soil data was designed. A self-attention mechanism was introduced to automatically reduce the dimensionality of redundant spectral data, and a feature fusion structure using graph features was employed for feature extraction. Finally, the performance of the algorithm was validated using a collected soil contaminant dataset. The experimental results demonstrate that the proposed method effectively reduces the dimensionality of hyperspectral data, decreases data redundancy, and achieves good performance and accuracy in soil contaminant detection by incorporating graph features. This method is of practical significance for the rapid detection of soil contaminants.

**Keywords:** hyperspectral, soil contamination, attention mechanism

### 0 引言

随着工业化和城市化的快速发展,土壤污染问题逐渐引起了人们的广泛关注。土壤污染物的存在对生态环境和人类健康造成了严重的威胁,因此高效准确地进行土壤污染物检测变得至关重要。传统的土壤污染物检测方法通常依赖于实验室化学分析,这种方法费时费力且成本高昂。而高光谱图像技术的引入为土

壤污染物检测提供了一种新的途径。

高光谱图像技术可以获取土壤在数百个连续波段上的光谱信息,这使得我们能够更全面地了解土壤的化学特性。通过分析土壤的高光谱图像,可以获得丰富的光谱特征,这些特征对于土壤污染物的检测和分类具有重要意义。然而,高光谱图像数据的高维度和复杂性给传统的分析方法带来了挑战,需要一种高效准确的算法来处理和解释这些数据。卷积神经网络

收稿日期: 2023-12-15; 修订日期: 2025-04-07.

作者简介: 叶叶 (1981-), 女, 硕士, 讲师, 主要从事土壤检测、人工智能、数据处理的研究。E-mail: nedcome@163.com.

基金项目: 江苏省高校哲学社会科学研究项目 (2022SJYB2329), 泰州学院 2021 年度教育教学改革研究课题 (2021JGB05), 泰州市软科学研究计划项目 (RKX20210024)。

(convolutional neural network, CNN)作为一种强大的深度学习算法,在图像识别和分类领域取得了显著的成功。CNN能够从数据中自动学习特征,具有较强的表征能力和泛化能力。近年来,越来越多的研究将CNN应用于高光谱图像的处理和分析,取得了令人瞩目的成果。然而,目前在高光谱土壤污染物检测方面的研究还相对较少。

针对以上问题和挑战,本研究旨在探索基于CNN的高光谱土壤污染物检测方法。通过构建适应高光谱土壤数据特点的CNN网络架构,利用高光谱图像的光谱特征和空间信息,实现对土壤污染物的快速准确检测和分类。我们将收集包含多个波段的高光谱土壤数据集,并对其进行预处理和特征提取。通过实验评估和性能分析,验证所提出方法的有效性和可行性。本论文的研究结果将为土壤污染物的检测提供一种新的方法和技术,具有重要的科学意义和实际应用价值。相信基于CNN的高光谱土壤污染物检测方法将在环境监测和土壤管理领域发挥重要作用,为保护生态环境和人类健康做出积极贡献。

## 1 相关工作

基于CNN的高光谱土壤污染物检测算法在国内外得到了广泛研究和应用。文献[1]提出了一种基于深度像素对特征的高光谱图像分类方法。通过使用CNN模型提取像素对的深度特征,实现了高准确度的分类结果。文献[2]介绍了一种基于深度局部模式的高光谱图像分类方法。研究人员提出了一种局部模式表示方法,并将其与CNN结合,实现了对土壤污染物的准确分类。文献[3]提出了一种基于注意力机制的高光谱图像分类方法。通过引入双分支卷积神经网络和注意力机制,实现了对土壤污染物的准确分类。文献[4]介绍了一种基于自适应双分支卷积神经网络的高光谱图像分类方法。研究人员提出了一种自适应的网络结构,可以自动学习适应不同土壤污染物的特征,提高分类的准确性。文献[5]提出了一种基于多尺度超图卷积网络的高光谱图像分类方法。通过建立超图卷积模型,并考虑多尺度特征的关联性,实现了对土壤污染物的精确分类。文献[6]提出了一种基于双路径注意力机制的卷积神经网络用于高光谱图像分类。通过引入并行的注意力机制,网络可以自适应地选择和整合不同尺度的特征信息,从而提高土壤污染物分类的准确性。文献[7]提出了一种基于双流深度残差网络的高光谱图像分类方法。通过同时利用空间信息和光谱信息,双流网络可以更好地捕捉土壤污染物的特征,提高分类准确率。文献[8]结合马尔可夫随机场和卷积神经网络

提出了一种高光谱图像分类方法。通过融合局部和全局上下文信息,该方法能够更好地处理土壤污染物的分类问题。文献[9]基于卷积神经网络提出了一种高光谱图像的深度特征提取和分类方法。通过多层卷积和池化操作,网络能够自动学习土壤污染物的特征,并实现准确的分类。文献[10]提出了一种深度空间-光谱融合网络,用于高光谱图像分类。通过同时考虑空间和光谱信息,并采用融合策略,该网络能够有效地提取土壤污染物的特征,实现准确的分类。

尽管CNN算法在土壤污染物检测中取得了一定的成果,但仍存在一些不足之处,包括:

1) 光谱特征提取:高光谱数据通常具有大量的波段,而传统的CNN结构对于高维输入数据的处理能力有限。在一些情况下,仅使用传统的CNN结构可能无法充分挖掘和利用高光谱数据中的特征信息。因此,需要进一步研究改进的网络结构或特征提取方法,以更好地捕捉土壤污染物的特征。

2) 模型泛化能力:由于土壤污染物检测涉及到不同地理位置和环境条件下的土壤样本,模型的泛化能力是一个关键问题。在一些情况下,已有的CNN模型可能无法适应新的土壤样本。因此,需要更多的研究来提高模型的泛化性能,例如迁移学习、领域自适应等方法。

3) 解释性和可解释性:CNN模型通常被视为黑盒模型,难以解释模型的决策过程。在土壤污染物检测中,模型的解释性和可解释性对于决策支持和专家系统的应用至关重要。因此,研究者们需要探索如何增强CNN模型的解释性,使其能够提供对土壤污染物检测结果的合理解释。

基于此,本文提出一种新的用于处理土壤高光谱数据的算法,该算法充分考虑了高光谱数据的空间特性与谱特性,从图像和光谱两个角度构建了网络模型,主要思想为:①通过加入自注意力机制,以学习的形式对高光谱数据进行自适应降维,降低冗余数据对土壤污染物语义特征的影响;②充分考虑空间特征与谱特征的有效融合,构建了轻量级图谱特征融合结构。我们以土壤重金属镉(Cd)、铜(Cu)、铬(Cr)和汞(Hg)为检测目标,结合采集到的带标注样本,提出一种基于图谱融合的有监督高光谱土壤重金属类别判断方法。实验以人工制作的土壤样本为对象,开展对4种金属不同含量级别的实验验证。实验结果表明,本文所提出的方法能实现高光谱数据的自动降维、特征提取和成分分类,表现出极强的土壤重金属识别能力。

## 2 研究方法

## 2.1 高光谱数据特性

高光谱成像技术结合了成像技术和光谱探测技术的优势,获得的高光谱数据是一个三维数据立方体,能够同时得到样本的光谱信息和空间信息。图 1(a)为高光谱数据结构示意图。

1) 空间信息:高光谱数据中的每一个波段都对应一个图像数据,该图像可以反映某一像元的位置信息和相邻像元之间的位置关系。如图 1(b)所示。

2) 光谱信息:高光谱数据中的每一个像素点都能够提取出一条光谱曲线,光谱曲线表示这一像素点的光谱特征,如图 1(c)所示。在高光谱图像中,同一类别的光谱曲线相似,不同类别的光谱特征不同。

在实际运用中,样本复杂的光谱信号往往受到杂散光、设备暗电流噪声、基线漂移等因素的干扰,采集到的高光谱数据不可避免地会包含噪声,这些噪声的存在会对后续数据处理产生不利影响,从而影响后续模型的建模分析效果,因此有必要在建模分析前对原始光谱数据进行预处理。

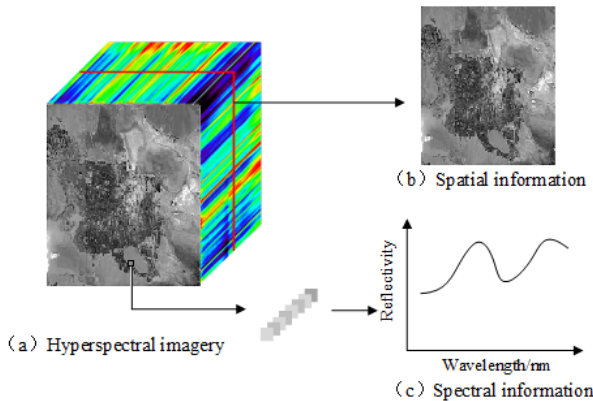


图 1 高光谱图像数据示意图

Fig.1 Schematic diagram of hyperspectral image data

## 2.2 基于注意力机制的 CNN 高光谱数据处理方法

CNN 是一种用于图像识别和处理的深度学习模型,通过使用卷积层、池化层和全连接层等组件,可以有效地从图像中提取特征并进行分类或回归等任务。CNN 的关键思想是通过卷积操作和权值共享,能够捕捉图像中的局部特征,并具备平移不变性。而注意力机制则是一种重点关注感兴趣区域或特定特征的机制。在深度学习中,注意力机制可以用于调整模型对输入数据中不同部分的关注程度,使模型能够在重要的区域或特征上进行更集中的处理。通过引入注意力机制,模型可以自动学习数据中的关键信息,并根据其重要性进行加权,这与高光谱数据预处理中滤波和降维不谋而合,因此,本文提出了基于注意力机制的 CNN 高光谱数据处理方法。

本文所设计的高光谱数据注意力模块如图 2 所

示,图中每个方块表示网络中的特征图, $X$  表示输入数据, $U$  表示处理过程中的特征图,表示输出的特征图。其中  $H$ 、 $W$  和  $C$  分别表示数据的高、宽和通道数。梯度传播过程中  $U$  与一个尺寸为  $1 \times 1 \times C$  的向量相乘,用以调整各通道中权重占比,凸显高光谱数据中与检测目标高相关的数据,弱化低相关数据,实现数据的自动降维。




图 2 高光谱数据注意力模块

Fig.2 Attention module for hyperspectral data

对于高光谱图像的每个像素  $p$ ,可以使用一个特征提取函数  $F()$  来提取其特征向量  $\vec{f}_p$ 。这可以表示为:

$$\vec{f}_p = F(p) \quad (1)$$

图像特征使用经典算法 ResNet 进行提取,使用  $\vec{f}_R$  表示空间特征。注意力计算权重  $A_{ij}$  表示的是图像特征中第  $i$  个元素对第  $j$  个元素的注意力权重。这个权重是通过计算两个元素特征的点积,然后通过 softmax 函数进行归一化得到的。所提出的机制允许模型动态地集中注意力于那些对当前任务最重要的元素上,在高光谱土壤污染物检测的上下文中,模型可能会更关注那些与特定污染物类型相关的波段特征。

$$A_{ij} = \frac{\exp(\vec{f}_{Ri}^T \vec{f}_{Rj})}{\sum_k \exp(\vec{f}_{Ri}^T \vec{f}_{Rk})} \quad (2)$$

随后再将权重  $A_{ij}$  与光谱特征进行  $\vec{f}_R$  融合,公式如下:

$$\vec{f}_{\text{fusion}} = A_{ij} \cdot \vec{f}_R + (1 - A_{ij}) \cdot \vec{f}_p \quad (3)$$

基于注意力模块,本文设计了针对土壤高光谱数据的污染物检测算法模型,如图 3 所示,算法将高光谱相机采集到的原始高光谱数据经过 2 个卷积层,增加数据通道数;然后经过  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  三个不同尺寸卷积核支路,使用注意力模块对特征进行自动权重计算;最后将 3 个不同支路提取到的特征进行级联拼接,经过全连接分类层输出高光谱数据对应金属污染物类别。这种方式,能够确保每个分支结构都能提

取到不同尺寸的特征细节，进而确保收集到了数据中所有有效特征。

3 实验及数据分析

3.1 土壤样品

本文的研究对象包含重金属镉（Cd）、铜（Cu）、铬（Cr）和汞（Hg）四类，制作了包含 4 种重金属的标准土壤，根据土壤中可能出现的浓度范围，每种重金属包含 5 种不同的浓度。由于实际土壤中 Cr 浓度往往低于 500 mg/kg，Hg 浓度低于 80 mg/kg，故这两类只包含 4 种浓度。具体浓度如表 1 所示，制作过程如图 4 所示。制作的土壤样本作通风阴干处理，经压碎研磨后，过筛备用。在样品制备过程中，我们通过电感耦合等离子体原子发射光谱法对每个样品的性质进行检测，检测目标为 Cu、Cd、Cr 和 Hg 等重金属的含量，验证每个样品重金属含量是否与标准值一致。

该方法在测定时，先进行微波消解，冷却后加超纯水摇匀，再按提前确定好的参数检测样本里元素的发射强度，并基于校准函数计算出重金属元素的含量。实验结果表明，所有样品重金属含量与标准值相对误差低于 2%，故认为表 1 中样品重金属含量准确。

3.2 数据集制作

数据采集源自便携式光谱仪 FieldSpec HandHeld 2 在室内测量土壤的光谱。光谱仪的波段范围在 350~2600 nm 之间，光谱采样间隔为 3 nm。我们将土样放置在直径为 10 cm、深度为 3.5 cm 的黑色器皿内，以使土壤表面呈现自然状态。我们选择了一盏 65 W 的卤素灯作为唯一的光源，将光源照射角度设置为 30 度，探头距离土样的距离为 25 cm，而光源距离土样的距离为 50 cm。为了测量土壤的反射光谱，我们要求光谱仪的测量方向与土壤表面垂直，并使用一个尺寸为 50 cm×50 cm 的白板进行定标，以获取土壤的绝对反射率。图 5 展示了 70 mg/kg Cu 采集到的一帧高光谱图像中的数据，每条曲线表示一个像素点的反射光谱。

实验中我们对每种重金属的不同含量样本各采集 50 次，并进行标注，总共得到 900 个带标签的高光谱数据，我们将其按照 8:2 分为训练集和验证集，即训练集 720 个高光谱数据，验证集 180 个高光谱数据。根据表 1，对高光谱数据进行标注，如 70 mg/kg 的 Cu 数据标注为 Cu-1，500 mg/kg 的 Cr 数据标注为 Cr-4 等。

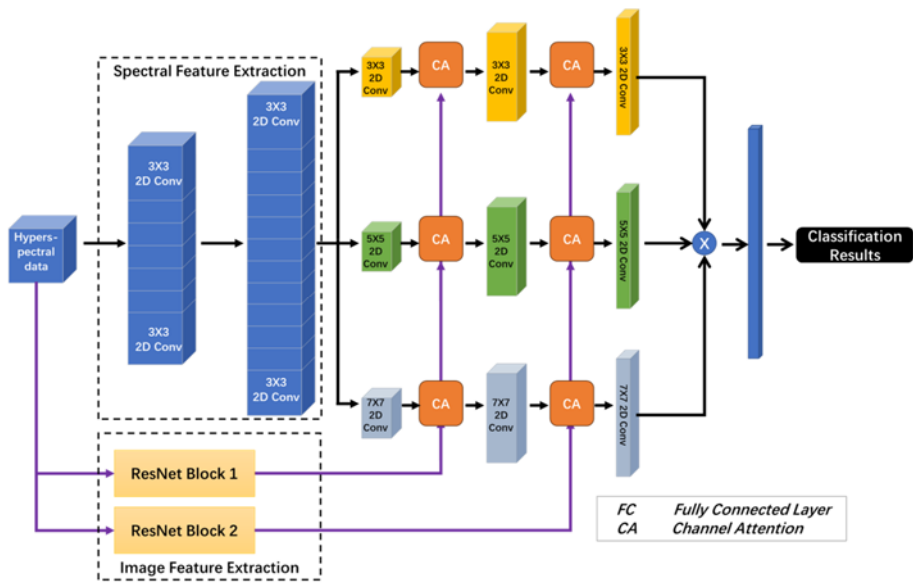


图 3 高光谱数据土壤重金属分类模型

Fig.3 Soil heavy metal classification model for hyperspectral data

表 1 土壤中重金属含量

Table 1 Heavy metal content in soil

Category	mg/kg				
	Content 1	Content 2	Content 3	Content 4	Content 5
Cu	70	150	250	500	1000
Cd	3	6	12	25	50
Cr	60	120	250	500	-
Hg	10	20	40	80	-



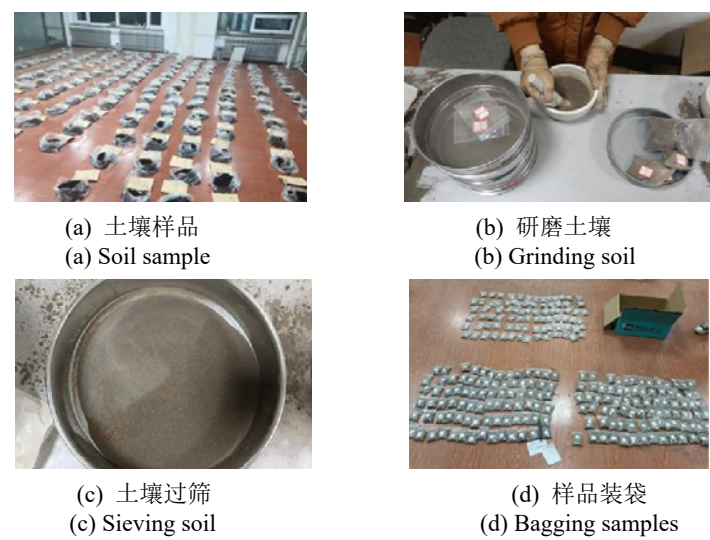


图4  土壤样品制作过程




图5  70mg/kg Cu 土壤高光谱反射曲线

Fig.5 Hyperspectral reflectance curves of 70mg/kg Cu soil

为了进一步验证本文所提出算法对重金属含量的识别效果和能力，在标准含量土壤中，我们加入少量不含重金属的纯净土壤，随机降低土壤中重金属含量，并以此为对象采集高光谱数据，作为测试集验证算法泛化能力。同样使用电感耦合等离子体原子发射光谱法测量新样品金属浓度，总共包含 90 个测试数据，测试集数据分布如表 2 所示。

3.3 实验及数据分析

我们将制作的训练集及验证集送入模型进行训练，所使用的深度学习框架为 Pytorch1.13.1，训练用的计算机硬件平台为处理器 AMD5950X，GPU 为 RTX3090。学习率设置为 0.01，每次迭代衰减为 90%。训练过程如图 6 所示，使用平均精度（mean accuracy, macc）和损失值（loss）观测训练过程，图中可以明显看出，模型在 20 个迭代周期以后快速收敛到一个较高水平，最终结果 macc 为 97.1%，即算法对训练集中不同重金属种类检测精确率高达 97.1%。

在模型泛化能力实验中，我们将测试集数据送入

训练好的模型中进行验证，结果如表 2 所示。表中可以看出，算法对随机重金属含量土壤的识别仍然保持在较高水平，只有低含量 Cd 和 Hg 中出现了 1 个错检，说明本文所提出的基于注意力机制的高光谱土壤污染物检测方法检测效果好，泛化能力强，能有效检测出土壤中 Cu、Cd、Cr 和 Hg 四种重金属的含量级别。

表 2  测试集检测结果

Table 2 The detection results of the test set					
Type	Content /(mg/kg)	Data quantity	Label	Correctly detection	False detection
Cu	61-68	5	Cu-1	5	0
	133-138	5	Cu-2	5	0
	242-247	5	Cu-3	5	0
	481-495	5	Cu-4	5	0
	977-993	5	Cu-5	5	0
Cd	1-3	5	Cd-1	4	1
	4-5	5	Cd-2	4	1
	8-11	5	Cd-3	5	0
	18-24	5	Cd-4	5	0
	42-47	5	Cd-5	5	0
Cr	45-58	5	Cr-1	5	0
	107-118	5	Cr-2	5	0
	221-247	5	Cr-3	5	0
	477-495	5	Cr-4	5	0
Hg	7-9	5	Hg-1	4	1
	14-19	5	Hg-2	5	0
	31-38	5	Hg-3	5	0
	62-79	5	Hg-4	5	0

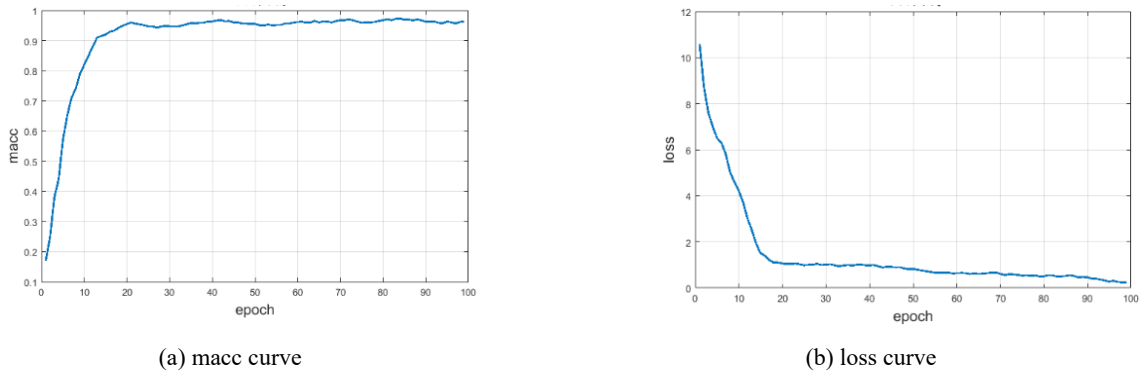


图 6 模型训练过程

Fig.6 Model training process

4 结语

高光谱图像是一种蕴含丰富光谱和空间信息的图像，已经成功应用于地质勘探、城市测绘、环境监测和农业病虫害检测等领域。然而，在传统的高光谱图像分类方法中，一些方法仅利用了光谱信息，而另一些方法虽然结合了空间信息，但并未充分利用两者之间的关联。这会对最终的分类结果产生影响。因此，当前研究的焦点是如何充分利用高光谱图像中的光谱和空间联合信息，从而获得有效的光谱-空间联合特征。

针对基于深度学习的分类方法存在计算量大、空间卷积尺度单一以及未充分利用光谱和空间信息等问题，本文提出了一种基于注意力机制和多尺度混合卷积神经网络（CNN）的高光谱图像分类方法。首先，经过降维处理的数据通过两层三维卷积进行初步的光谱-空间特征提取。然后，为了减少模型的计算量，并能够提取更抽象的光谱-空间特征，该方法利用不同尺度的二维卷积来进一步提取多尺度的抽象光谱-空间特征。最后，为了更充分地利用有效的光谱和空间信息，以达到最大可能的分类准确性，该方法在模型中添加了通道和空间注意力模块来进一步提取关键的光谱-空间特征。

实验结果表明，所提出的方法在自制的土壤重金属数据集上取得了优秀的分类指标，并且展现出出色的分类效果。这表明该方法在高光谱土壤重金属分类任务中是有效的，有较强的实际意义。

参考文献:

[1] LI J, HU W, LI Z, et al. Hyperspectral image classification with deep pixel-pair features[J]. *Remote Sensing*, 2018, **10**(3): 438.

[2] CHEN Y, XIE W, ZHANG L, et al. Hyperspectral image classification with deep local patterns[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **57**(1): 84-95.

[3] SHI C, LIAO D, XIONG Y, et al. Hyperspectral image classification based on dual-branch spectral multiscale attention network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, **14**: 10450-10467.

[4] LIU H, DU Q, YANG Y. Hyperspectral image classification with self-adaptive dual-branch convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, **58**(8): 5575-5587.

[5] LI R, DU Q, YANG Y. Multi-scale hypergraph convolutional networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **59**(8): 6786-6798.

[6] ZHANG Y, HAN J, ZHANG L. Dual-path attention-based convolutional neural networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, **58**(5): 3704-3719.

[7] WEI H, WU C, ZHANG L. Dual-stream deep residual networks for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, **14**: 4230-4242.

[8] ZHANG L, LI J, LI Z, et al. Hyperspectral image classification with Markov random fields and convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, **56**(9): 5252-5266.

[9] LI X, ZHANG L, SHEN H, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *Remote Sensing*, 2019, **11**(11): 1344.

[10] WANG X, LI X, WEI H, et al. Deep spatial-spectral fusion network for hyperspectral image classification[J]. *Remote Sensing*, 2020, **12**(1): 124.