

DOI: 10.20098/j.cnki.1001-5132.2025.0914

基于 BIM+Conv6 与 CBAM 的地质土层识别与厚度预测深度学习模型

胡秀宇^{1,2}, 赵阿丽³

(1.北京理工大学 计算机学院, 北京 100081; 2.中交基础设施养护集团有限公司, 北京 100011;
3.中国建筑科学研究院有限公司, 北京 100013)

摘要: 针对传统方法在土层识别中依赖人工、效率较低的问题, 提出一种基于深度学习的多任务模型, 用于同时实现土层图像的分类与厚度回归。该模型在深度卷积神经网络基础上引入六层卷积 (Conv6) 特征提取结构, 以增强复杂纹理与边界的多尺度感知能力; 同时嵌入卷积块注意力模块 (CBAM), 在通道与空间维度上实现关键区域的自适应特征增强, 并通过建筑信息模型标准化输入方式, 确保土层图像与厚度数据在空间维度上的一一对应关系。实验结果表明, 模型在土层识别任务中取得较高精度, 在 30 孔测试集上, 准确率达到 92.31%, F1 分数达到 0.889, 证明了模型在分类任务上的优越性; 在厚度回归预测中也表现出良好的效果。

关键词: BIM; 土层识别; 厚度预测; CBAM; 深度学习

中图分类号: TP18; U442

文献标志码: A

文章编号: 1001-5132 (2026) 02-0001-10

Deep learning model for geological soil layer identification and thickness prediction based on BIM, Conv6, and CBAM

HU Xiuyu^{1,2}, ZHAO Ali³

(1.School of Computer Science & Technology, Beijing Institute of Technology, Beijing 100081, China; 2.CCCC Infrastructure Maintenance Group Co., Ltd., Beijing 100011, China; 3.China Academy of Building Research, Beijing 100013, China)

Abstract: To address the problem that traditional soil layer identification methods rely heavily on manual work and suffer from low efficiency, this paper proposes a deep learning-based multi-task model that simultaneously performs soil layer image classification and thickness regression. Based on a deep convolutional neural network, the proposed model introduces a six-layer convolutional (Conv6) feature extraction structure to enhance the multi-scale perception of complex textures and boundaries. Meanwhile, a Convolutional Block Attention Module (CBAM) is embedded to achieve adaptive feature enhancement in both the channel and spatial dimensions. Through a BIM-standardized input approach, the spatial correspondence between soil layer images and thickness data is ensured. Experimental results show that the proposed model achieves high accuracy in soil layer recognition, reaching an accuracy of 92.31% and an F1-score of 0.889 on a 30-borehole test set, demonstrating its superiority in classification tasks. In thickness regression prediction, the model also exhibits favorable performance.

Keywords: BIM; soil layer identification; thickness prediction; CBAM; deep learning

收稿日期: 2025-09-28

宁波大学学报(理工版)网址: <http://journal.lg.nbu.edu.cn/>

基金项目: 国家重点研发计划 (2024YFC3809601)

第一作者: 胡秀宇, 硕士研究生/高级工程师, 主要研究方向为数字化及 BIM 技术应用。E-mail: huwei2003@126.com

随着建筑信息模型(BIM)技术逐步在地质建模中的推广应用,地质土层信息三维表达与智能分析的应用潜力日益显现。三维地质建模可以直观展示地下土层结构和厚度分布,为工程设计、施工决策及地基处理提供重要支撑。例如,使用 Civil 3D 软件建立水运工程地质覆盖层模型和三维地质模型^[1]。孙凯强等^[2]基于 Dynamo 可视化编程实现 BIM 环境中地质模型创建。向卫国等^[3]利用 BIM 软件与 Dynamo 相结合的方法进行桩基建模。利用 BIM 技术快速建立地质钻孔土层三维模型已成为目前的研究热点。

在地质勘察中,钻探取样是获取地下岩土样本的主要手段,而土层的判别主要依赖地质工程师人工判断^[4]。这种方法存在主观性强、效率低、难以应对复杂地质条件等问题,影响勘察结果的准确性和一致性。同时,地质钻孔通常呈现上下分层结构,不同土层在颜色、纹理和颗粒特性上存在差异,但层间边界模糊,颜色相近的土层易混淆,增加了分类和厚度预测难度。例如,淤泥层纹理细腻,颜色深灰至褐色,边界不清晰,厚度难以准确估计;粉砂层颗粒明显,纹理呈条状,但局部纹理易受光照或拍摄角度影响而缺失。

近年来,人工智能技术在地质领域得到广泛应用。李灿锋等^[5]探索人工智能技术在基础地质、能源矿产、地质灾害等方面的应用。高源等^[6]利用人工智能算法进行地层划分,取得了较好的结果。在岩石图像识别方面,王晓兵等^[7]结合卷积神经残差 ResNet50 网络构建识别模型,实现了黑云母花岗闪长岩、变质砂岩、石英岩、黑云母花岗岩等岩性分类。许多学者还利用卷积神经网络和迁移学习方法,实现岩性的自动识别和分类^[8-13]。Banoth 等^[14]将 MobileNet V2 与 CNN 结合,用红土、黏土、黑土和黄土训练土壤分类模型,也取得较好效果。然而,目前大部分研究都聚焦于图像清晰、纹理明显的岩层,对于钻孔土层的识别,尤其是土层厚度预测研究较少。

此外,注意力机制在土壤图像识别中表现出较高特征提取能力。刘康等^[15]提出将大核注意力机制(LKA)与 ResNet 融合的 VAR 模型,用于土壤种类识别,显著提高了难分类样本的识别精度,并增强了模型对关键纹理结构的感知能力。但将注意力

机制应用于钻孔土层识别的研究仍几乎为空。

针对上述问题,为提升钻孔土层图像的语义表达能力与特征区分度,本文在模型设计上进行三方面改进:

(1) BIM 标准化输入机制:通过对钻孔图像与 BIM 地层模型的语义对齐,实现样本在空间坐标与地层属性上的统一,为多任务学习提供标准化输入。

(2) Conv6 结构改进:采用六层卷积层替代传统浅层 CNN 结构,结合不同尺度卷积核与跨层特征融合机制,增强模型对土层纹理变化、颗粒结构及模糊边界的多尺度表征能力。

(3) CBAM 自适应特征增强模块:通过通道注意力与空间注意力的级联机制,模型能够自动聚焦于关键层位和纹理突变区域,从而在复杂背景下仍保持较高的识别鲁棒性。

本文提出一种结合 BIM 模型的 Conv6+CBAM 多任务深度学习框架,在同一网络结构中实现土层类型识别与厚度预测。通过 BIM 标准化输入增强地层样本的语义一致性,Conv6 模块强化局部纹理特征提取,CBAM 模块实现关键层位特征自适应增强。实验结果表明,该方法在分类精度和厚度预测稳定性方面均优于传统 CNN 与 ResNet 网络,证明了模型在复杂土层识别中的有效性与泛化能力。

1 整体算法框架

针对钻探取样的钻芯土层样本,如何快速识别每一层土的类别和厚度是地质勘察工作中的关键任务。自然土层图像通常层间边界模糊,色调连续性强,纹理局部不显著。针对上述难点,本文提出一种融合 BIM 模型、改进型 Conv6 结构与 CBAM 注意力机制的双任务深度学习框架。该方法在统一 BIM 数据输入格式基础上,通过六层卷积结构强化多尺度纹理感知,并利用 CBAM 模块实现特征自适应增强,实现土层类别识别与厚度回归预测的联合优化。本算法框架由四个模块构成。

(1) 改进型卷积特征提取模块(Conv6)。在传统 CNN 的基础上增加至六层卷积单元,并在不同尺度层中融合局部与全局纹理特征。此结构使网络具备更强的层间纹理建模能力,能够更好地捕捉钻孔图像中的渐变层理特征与边界细节,为厚度预

测提供充分的空间上下文支撑。

(2) CBAM 注意力模块。结合通道与空间注意力机制, 针对钻孔图像中色差弱、纹理模糊的特点, 自适应突出关键纹理与边界特征, 该模块能有效提升模型对复杂地层特征的区分能力。

(3) 分类分支。采用 Softmax 输出并结合 Focal Loss 有效提升对模糊边界和难分类土层的判别能力。

(4) 回归分支。通过多层全连接结构并结合 Smooth L1 Loss, 优化连续厚度预测, 并在厚度突变情况下保持预测稳定性。

通过上述设计, 本文模型能从 BIM 钻孔土层图像中同时实现土层类型识别与厚度预测, 在纹理细微、颜色相近、边界模糊及厚度突变等复杂情形下仍具备鲁棒性与适应性。整体框架如图 1 所示。

1.1 BIM 地质钻孔建模技术

为了提供规范化的土层图像和厚度信息, 本研究引入 BIM 技术构建钻孔土层三维模型, 实现土层空间位置标准化和可视化。在 BIM 钻孔建模过程中, BIM 材质采用真实钻孔土层照片制作, 像素高度与实际土层厚度一一对应, 用于生成训练数据

的标准化图像。这样不仅提供了可视化的三维土层模型, 也为深度学习模型训练提供了标准化的输入数据。模型能够在具备纹理、颜色和边界信息的同时, 获得土层厚度的连续标签, 为后续卷积神经网络与 CBAM 注意力模块的训练奠定基础。建模流程如图 2 所示。

1.2 卷积特征提取层

传统浅层 CNN 结构在处理地质钻孔图像时, 容易忽略层理纹理的渐变性与局部细节特征。为此, 本文设计了改进的六层卷积特征提取模块 (Conv6), 通过更深层的卷积堆叠与跨层信息融合, 实现多尺度空间纹理与边界特征的联合建模。每层由卷积 (Conv2D)、批归一化 (BatchNorm)、非线性激活 (ReLU) 以及最大池化 (MaxPooling) 构成, 以增强模型对复杂地质结构的适应能力。第 l 层卷积操作如下:

$$F^{(l)} = \text{MaxPool} \left(\text{ReLU} \left(\text{BN} (W^{(l)} * F^{(l-1)} + b^{(l)}) \right) \right) \quad (1)$$

式中: $*$ 表示卷积操作; $F^{(l-1)}$ 为前一层输出特征图; $W^{(l)}$ 为卷积核权重; $b^{(l)}$ 为偏置。




图1 神经网络结构




图2 地层与钻孔 BIM 建模流程

1.3 CBAM 注意力机制

为更有效地提升模型对复杂土层图像中不同特征的识别能力,在主干特征提取网络后引入 CBAM 注意力机制模块,增强模型对关键区域的关注能力。CBAM 模块结合通道注意力与空间注意力,能够在特征图的维度空间中动态调整信息权重,从而提升模型对不同土层纹理、颜色及边界特征的感知能力, CBAM 注意力机制结构如图 3 所示。通道注意力 (M_c) 可表示为

$$M_c = \sigma \left(W_1 \left(\text{ReLU} \left(W_0 (F_{\text{avg}}) \right) \right) + W_1 \left(\text{ReLU} \left(W_0 (F_{\text{max}}) \right) \right) \right) \quad (2)$$

式中: F_{avg} 与 F_{max} 分别为输入特征图的全局平均池化和最大池化结果; W_0 与 W_1 为可训练权重矩阵; σ 为 Sigmoid 激活函数。




图 3 CBAM 结构

1.4 分类分支

为应对土层图像中颜色相近、纹理模糊等引起的类别混淆问题,分类分支设计以 Softmax 归一化输出,并采用 Focal Loss 作为目标函数以增强模型对少数类的关注。此损失函数的核心优势在于它通过放大难分类样本对总损失的贡献,帮助模型更加关注稀有或边界不清的土层类型,从而提高类别不平衡下的识别精度。

$$L_{\text{focal}} = -\alpha_i (1 - p_i)^\gamma \lg p_i \quad (3)$$

式中: p_i 为正类的预测概率; α_i 控制样本权重; γ 调节难易样本的关注度,当 $\gamma > 0$ 时,难分类样本会被赋予更高的权重。

1.5 回归分支

土层厚度具有连续性,变化尺度大,并受图像垂直像素分布影响显著,因此回归分支用于建模像素级厚度信息。该分支通过多层全连接网络输出厚度预测值,并采用 Smooth L1 Loss 作为优化目标。相比传统均方误差损失,Smooth L1 Loss 在大误差情况下减弱梯度惩罚,从而兼顾小误差的精确拟合和大误差的稳健性,尤其适用于图像中局部厚度突变的场景。

$$L_{\text{Smooth}}(x, y) = \begin{cases} 0.5(x - y)^2, & |x - y| < 1 \\ |x - y| - 0.5, & |x - y| \geq 1 \end{cases} \quad (4)$$

式中: x 为预测厚度; y 为真实厚度。

2 工程实例

2.1 工程概况

本研究数据来源于某训练基地地质勘察区域,共计 38 处钻孔。选取其中 30 孔进行研究,覆盖典型多层土壤结构,勘探深度 30~60 m,地表标高 3.06~4.89 m。土层类型包括淤泥、粉质黏土、粉土、粉砂、黏土、中砂等,具有代表性与复杂性(图 4),各钻孔的基本参数与土层分布情况见表 1。




图 4 地质剖面

表 1 各钻孔的基本参数与土层分布情况

序号	勘探点编号	勘探深度/m	地表标高/m	钻孔土层层数					
				淤泥	粉质黏土	粉土	粉砂	黏土	中砂
1	QK1	40.00	4.47	1	2	1	3	2	0
2	QK2	37.85	4.89	1	2	2	3	0	0
3	QK3	37.50	4.36	1	3	3	2	1	0
4	QK4	51.91	3.83	1	2	2	3	1	0
5	QK5	36.95	3.80	1	2	1	4	0	0
6	QK6	55.00	3.77	1	3	2	6	0	1
7	QK7	37.50	3.74	1	3	1	3	0	0
8	QK8	37.95	3.71	1	3	1	4	0	0
9	QK9	37.45	3.68	1	3	0	3	0	0
10	QK10	52.85	3.65	1	5	5	5	0	1
11	QK11	37.45	3.62	1	2	2	3	0	0
12	QK12	37.85	3.59	1	5	2	3	0	0
13	QK13	37.45	3.56	1	5	2	2	0	0
14	QK14	37.85	3.53	1	5	1	1	0	0
15	QK15	37.45	3.50	1	5	1	2	0	0
16	QK16	47.80	3.47	1	7	1	3	0	0
17	MK1	60.00	3.44	1	5	4	3	1	1
18	MK2	50.00	3.41	1	3	3	2	1	0
19	MK3	50.00	3.38	1	3	3	2	1	0
20	MK4	50.00	3.35	1	3	3	2	1	0
21	MK5	48.00	3.06	1	3	3	1	1	0
22	MK6	58.35	3.25	1	3	3	2	1	1
23	GK1	34.00	3.44	1	0	1	0	2	4
24	GK2	36.50	3.63	1	0	1	0	2	4
25	GK3	30.00	3.82	1	0	1	0	2	4
26	GK4	32.00	4.01	1	0	1	0	2	4
27	GK5	34.50	4.20	1	0	1	0	3	3
28	GK6	39.00	4.39	1	0	1	0	3	3
29	GK7	42.00	4.58	1	0	1	0	3	3
30	GK8	35.50	4.77	1	0	1	0	3	3

注：土层层数表示钻孔中该类土层的出现次数，非厚度值。

2.2 钻孔土层识别业务流程

结合 BIM 建模技术和神经网络模型方法，构建基于钻孔土层图像的多任务学习模型，实现土层

类型识别与厚度预测。具体建模流程如图 5 所示，包括数据准备、BIM 建模、图像标注及网络训练等环节。




图 5 土层识别业务流程

2.3 地层与钻孔建模

2.3.1 土层材质库创建

在 Revit 中新建地质材质库, 通过将现场采集的淤泥、粉土、粉砂、黏土等土层的高清照片导入到 Revit 材料模板中, 制作土层纹理材质, 确保保留每层土的纹理、颗粒与颜色特征(图 6)。




图 6 土层材质库

2.3.2 地层与钻孔模型创建

采用图 2 所示流程创建地层与钻孔模型。将钻孔坐标及厚度数据整理成 Excel 表格, 利用 Dynamo 软件的 point 节点提取坐标数据, 并通过 line 节点创建钻孔族模型。然后附加相应土层材质, 并通过 StructuralFraming 创建钻孔框架柱模型。最后通过批量生成方式创建地层与钻孔的三维模型(图 7)。



图 7 地层与钻孔模型

2.3.3 BIM 建模与图像-厚度关联

通过 BIM 建模, 将钻孔的空间坐标、厚度与对应土层图像进行关联, 实现土层图像的标准化管管理, 为卷积神经网络提供一致、准确的输入数据。

2.3.4 数据标注与图像处理

BIM 钻孔模型的每张图像由经验丰富的地质工程师使用 VIA 工具手动标注, 标注数据经过两轮交叉验证, 并以 JSON 格式存储, 确保数据的可重复使用和便于模型训练, 土层标注如图 8 所示。




图 8 钻孔土层标注

2.4 模型训练数据准备

为确保输入数据的标准化与模型的泛化能力, 本文采用 BIM 建模地质钻孔图像作为统一输入格式, 图像高度与真实厚度保持线性比例。相比传统摄影采集方式, BIM 模型不仅在空间坐标上具备精确性, 还实现厚度与像素的一一映射关系, 使网络能直接学习图像空间特征与厚度信息的内在耦合。在数据标注方面, 所有样本均采用 VIA 统一标签, 保证分类与回归任务输入的一致性。此 BIM 标准化输入机制为后续卷积特征提取和注意力增强提供了高质量的样本基础。

2.5 实例验证

为验证所提方法在实际工程中的适用性与有效性, 本研究选取 19 孔和 30 孔两组钻孔数据进行训练、验证与测试。

2.5.1 数据集划分

19 孔数据集按照 13:4:2 划分为训练集、验证集与测试集。每层均作为独立样本进行分类与厚度预测, 样本数量足以验证模型泛化能力。30 孔数据集按照 24:4:2 划分, 同样保证土层的多样性与完整性, 以进一步验证模型在较大样本规模下的稳定性与泛化能力。所有土层图像均经人工标注并进行标准化处理, 为模型训练提供一致数据。

2.5.2 评估指标

分类任务使用准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、F1 分数进行评估; 回归任务使用均方误差 (MSE) 和平均绝对误差 (MAE) 进行评估, 以全面衡量模型在土层识别与厚度预测任务中的性能。

2.5.3 参数设置

实验中, 分别采用传统 CNN、Conv6、ResNet50 和本文模型进行土层分类与厚度预测, 并对本文模型进行消融实验对比分析。在训练过程中, 采用 Adam 优化器, 学习率设置为 0.0001, 训练 50 轮, 早停 10 轮。

3 结果分析与评估

3.1 实验结果

本文采用 Conv6+CBAM 结构进行训练、验证和预测。通过上述实验设计, 模型在不同钻孔数据集上均能实现土层类别识别与厚度预测, 验证了所

提方法的有效性和工程适用性。图 9 展示了四层土层预测与真实标签的对比, 可直观反映模型对各土层纹理、边界和厚度的准确捕捉能力。




图 9 土层测试结果

3.2 结果分析

为验证所提 Conv6+CBAM 结构的有效性, 本文设计 4 组对比实验, 包括基础 CNN 结构、加深的 CNN (Conv6)、引入注意力机制的 Conv6+CBAM 以及主流卷积架构 ResNet50, 评估不同网络结构在土层识别与厚度预测上的性能。实验对比结果分类指标如图 10~11 所示, 土层厚度预测回归指标如图 12~13 所示。






图 10 损失和准确率曲线







图 11 精准率和 F1 分数曲线









图 12 MAE 和 MSE 曲线

图 13 R^2 曲线

从整体趋势上看, Conv6+CBAM 模型在分类精度与收敛稳定性上均优于基础 CNN 与 ResNet50 网络,表明本文提出的“Conv6 深层特征+注意力机制”在土层识别任务中具有显著优势。

(1) Conv6 结构改进作用。与传统 3~4 层 CNN 相比, Conv6 结构通过增加卷积层深度与跨层融合,能够捕捉不同尺度的纹理层理变化。图 10~11 的结果表明, Conv6 模型相较基础 CNN, F1 分数提升约 3%,说明多尺度卷积增强了模型的纹理表达能力。

(2) CBAM 注意力机制贡献。引入 CBAM 后,模型在类别边界模糊区域上的识别能力显著增强。由图 9 可见, Conv6+CBAM 在 F1 分数上继续

提升约 1.2%,验证集准确率稳定在 0.74~0.79 之间,表明注意力机制能够自适应强化关键地层边界特征与弱纹理区域。

(3) 回归任务表现分析。Conv6 模型在厚度预测上的 MAE 与 MSE 略优于 Conv6+CBAM,说明注意力机制在厚度连续特征学习中存在一定平滑效应。

综合分析, Conv6 模块强化了多尺度特征感知, CBAM 模块优化了特征分配与空间聚焦, 两者结合实现了分类精度与厚度预测精度的整体提升, 为土层识别任务提供了更具解释性与鲁棒性的结构设计。

3.3 测试集结果

CNN、ResNet50、Conv6 和本文提出模型的测试结果见表 2~4。

在 19 孔和 30 孔测试集上, Conv6+CBAM 模型表现如下:

(1) 土层识别: 30 孔测试中, 准确率 92.31%、F1 分数 0.889, 显著优于其他模型, 分类稳定性突

出; 19 孔测试中, 准确率与 Conv6 持平, 但 F1 分数更高, 说明模型在兼顾精度与召回率方面表现优异。

(2) 土层厚度回归: Conv6 在 MAE、MSE 和 R^2 上略优于 Conv6+CBAM, 回归性能表现更稳定。通过表 3 参数优化实验 (如学习率调整), Conv6+CBAM 可同时获得较优分类和回归性能, 表明模型在厚度预测上仍有优化空间。

综上, Conv6+CBAM 在分类任务上表现最佳, 回归任务可通过超参数和结构优化进一步提升。

4 结论

本研究在传统卷积神经网络的基础上, 提出融合 BIM 标准化输入、Conv6 多尺度特征提取与 CBAM 注意力机制的多任务学习框架, 实现了钻孔土层的类型识别与厚度预测。主要结论如下:

(1) 通过 BIM 数据标准化输入, 建立图像像素与真实厚度的线性映射, 实现统一比例输入与厚度标注, 为多任务学习提供高精度基础数据。

表 2 19 孔测试预测指标

算法	土层识别分类指标				土层厚度回归指标		
	准确率/%	精准率	召回率	F1 分数	MAE	MSE	R^2
CNN	79.31	0.69	0.79	0.73	0.57	0.62	0.93
ResNet50	79.31	0.86	0.79	0.71	2.31	36.58	0.52
Conv6	82.76	0.87	0.83	0.76	1.49	6.35	0.92
本文模型	82.76	0.82	0.83	0.88	3.36	50.04	0.35

表 3 30 孔测试预测指标

算法	土层识别分类指标				土层厚度回归指标		
	准确率/%	精准率	召回率	F1 分数	MAE	MSE	R^2
CNN	84.615	0.774	0.846	0.802	0.607	0.836	0.914
ResNet50	84.615	0.881	0.846	0.799	2.557	45.596	0.520
Conv6	84.615	0.893	0.846	0.796	2.229	15.642	0.835
本文模型	92.307	0.940	0.923	0.889	3.067	48.104	0.493

表 4 本模型不同参数敏感性测试结果 (30 孔)

参数设置	土层识别分类指标				土层厚度回归指标		
	准确率/%	精准率	召回率	F1 分数	MAE	MSE	R^2
训练 100 次	84.210	0.912	0.842	0.834	0.479	0.423	0.962
学习率 0.000 5	94.736	0.965	0.947	0.926	0.353	0.196	0.982
学习率 0.000 1、训练 50 次	92.307	0.940	0.923	0.889	3.067	48.104	0.493

(2) 通过 Conv6 深层卷积结构改进与特征跨层融合, 增强了模型对细粒纹理与层理过渡的感知能力, 显著提升分类精度。

(3) 采用 CBAM 自适应注意力增强机制, 融合通道与空间注意力权重, 自适应聚焦土层边界与关键区域, 提高模型在模糊边界与相似色调条件下的鲁棒性。

未来可以改进回归分支网络结构, 采用更适配的损失函数降低误差; 加强分类与回归任务间的信息交互, 提高互补性; 结合 Conv6 回归优势与 ResNet50 特征表达能力, 通过迁移学习或集成学习提升泛化性与精度。

参考文献:

- [1] 刘莉, 牛作鹏. 基于 Civil 3D 的三维地质覆盖层建模技术及应用[J]. 水运工程, 2021(4):153-157, 179.
- [2] 孙凯强, 刘惊灏, 苏谦, 等. 基于地质 BIM 模型与有限元分析的铁路高边坡多源融合健康监测[J]. 铁道标准设计, 2023, 67(11):31-37, 60.
- [3] 向卫国, 王富章, 赵鲁东, 等. 桩基工程 BIM 智能化建模及数据提取方法[J]. 铁道建筑, 2020, 60(3):77-81.
- [4] 吴明明. 水利工程中岩土工程勘察技术应用研究[J]. 工程机械与维修, 2024(5):88-90.
- [5] 李灿锋, 刘达, 周德坤, 等. 人工智能在地质领域的应用与展望[J]. 矿物岩石地球化学通报, 2023, 41(3):668-677.
- [6] 高源, 姚卫华, 蔡少锋, 等. 基于人工智能算法的地质分层技术及应用效果[J]. 测井技术, 2024, 48(2):204-214.
- [7] 王晓兵, 刘琳, 王俊卿, 等. 基于卷积神经 ResNet50 残差网络的岩石图像岩性识别研究[J]. 岩土工程技术, 2024, 38(3):294-302.
- [8] 冯雅兴, 龚希, 徐永洋, 等. 基于岩石新鲜面图像与孪生卷积神经网络的岩性识别方法研究[J]. 地理与地理信息科学, 2019, 35(5):89-94.
- [9] 赵兴东, 王宏宇, 白夜. 基于卷积神经网络迁移学习模型的矿岩智能识别方法[J]. 矿床地质, 2023, 42(5):1003-1010.
- [10] 马泽栋, 马雷, 李科, 等. 基于岩石图像深度学习的多尺度岩性识别[J]. 地质科技通报, 2022, 41(6):316-322.
- [11] 董文豪, 张怀. 基于迁移学习的岩屑岩性识别[J]. 中国科学院大学学报, 2023, 40(6):743-750.
- [12] 熊峰, 廖一凡, 曹伟腾, 等. 基于卷积神经网络-深度迁移学习的岩性自动识别研究[J]. 安全与环境工程, 2023, 30(4):26-34.
- [13] 宋明宇, 杨顺华, 孙正, 等. 基于随机森林和数字图像处理技术的黑土层识别[J]. 土壤通报, 2024, 55(6):1501-1511.
- [14] BANOTH R K, RAMANA MURTHY B V. Soil image classification using transfer learning approach: MobileNetV2 with CNN[J]. SN computer science, 2024, 5(1):199.
- [15] 刘康, 曾绍华, 胡静, 等. 融合大核注意力机制的土壤种类识别网络[J]. 重庆师范大学学报(自然科学版), 2023, 40(3):129-138.

(责任编辑 韩 超)