

基于图像数据驱动的冻土强度智能识别方法

姚兆明^{1,2}, 王 涣^{1,2}, 魏 航^{1,2}, 王晓龙^{1,2}

(1. 安徽理工大学 土木建筑学院, 安徽 淮南 232001; 2. 矿山地下工程教育部工程研究中心, 安徽 淮南 232001)

摘要: 在冻结法施工中, 保证冻结壁稳定性至关重要, 传统的现场检测方法因其间断性而无法提供实时监测, 限制了对冻结壁潜在灾变的及时响应, 采用冻土的深层原位精准探测是揭示冻结壁重大工程灾变机理及灾害预警的有效手段。基于卷积神经网络提出一种基于图像数据驱动的冻土强度智能识别方法, 通过对 93 组试样的多角度图像捕获及随后的单轴抗压强度试验, 标注试样图像与实际强度数据并结合图像数据增强技术, 构建了深度学习模型训练所需的图像数据集; 利用迁移学习深度残差网络 34 层 (ResNet-34) 模型, 并对比其他不同模型的训练过程和测试结果, 发现 ResNet-34 模型效果最佳, 准确率为 92.8%, 且没有出现过拟合现象; 应用深度学习模型对冻土强度的影响因素土质、温度和含水率进行识别, 发现模型能有效识别出 3 个变量, 证明了模型识别冻土强度的科学性和可靠性; 此外研究了模型在不同干扰条件下的表现, 模拟典型干扰场景并分析其对模型预测性能的影响, 为后续改进数据增强策略和模型优化方向提供依据; 引入 Grad-CAM(Gradient-weighted Class Activation Mapping) 可解释性分析方法揭示卷积神经网络在冻土强度识别任务中的内部特征提取过程, 发现利用模型能够提取和分析冻土的关键图像特征, 实现冻土强度的快速判识。研究成果为冻结壁状态的实时监控及早期灾害预警提供了新方法, 可为冻结工程施工提供技术支撑。

关键词: 冻土; 单轴抗压强度; 图像识别; 迁移学习; 可解释性分析

中图分类号: TD265.3 **文献标志码:** A **文章编号:** 0253-9993(2025)05-2761-12

Image data-driven intelligent recognition of permafrost strength and feature visualization based analysis

YAO Zhaoming^{1,2}, WANG Xun^{1,2}, WEI Hang^{1,2}, WANG Xiaolong^{1,2}

(1. College of Civil Engineering, Anhui University of Science and Technology, Huainan 232001, China; 2. Engineering Research Center of Underground Mine Construction, Ministry of Education, Huainan 232001, China)

Abstract: Ensuring the stability of the frozen wall is critical in freezing construction, but traditional onsite detection methods, due to their intermittent nature, fail to provide real-time monitoring, limiting timely responses to potential catastrophic events. Deep in-situ precise detection of frozen soil is an effective means to reveal the mechanisms of major engineering disasters in frozen walls and to provide disaster early warning. A convolutional neural network-based image data-driven intelligent recognition method for frozen soil strength is proposed. This method involves capturing multi-angle images of 93 sample specimens and conducting subsequent uniaxial compressive strength tests. The labeled sample images and actual strength data, combined with image data augmentation techniques, were used to construct the image dataset re-

收稿日期: 2024-07-03 策划编辑: 郭晓炜 责任编辑: 钱小静 DOI: [10.13225/j.cnki.jecs.2024.0771](https://doi.org/10.13225/j.cnki.jecs.2024.0771)

基金项目: 矿山地下工程教育部工程研究中心开放研究资助项目 (JYBGCZX2021104)

作者简介: 姚兆明 (1975—), 男, 安徽黄山人, 教授, 博士。E-mail: zhmyaoaust@126.com

通讯作者: 王 涣 (2000—), 男, 安徽黄山人, 硕士研究生。E-mail: sprite1007@126.com

引用格式: 姚兆明, 王涣, 魏航, 等. 基于图像数据驱动的冻土强度智能识别方法[J]. 煤炭学报, 2025, 50(5): 2761-2772.

YAO Zhaoming, WANG Xun, WEI Hang, et al. Image data-driven intelligent recognition of permafrost strength and feature visualization based analysis[J]. Journal of China Coal Society, 2025, 50(5): 2761-2772.



移动阅读

quired for training the deep learning model. A 34-layer deep residual network (ResNet-34) model using transfer learning was employed. By comparing the training processes and test results of different models, it was found that the ResNet-34 model performed the best, achieving an accuracy of 92.8% with no signs of overfitting. The deep learning model was applied to identify the influencing factors of frozen soil strength, including soil type, temperature, and moisture content. It was found that the model effectively recognized these three variables, demonstrating the scientific validity and reliability of the model in identifying frozen soil strength. In addition, the model's performance under different disturbance conditions was studied by simulating typical interference scenarios and analyzing their impact on the model's predictive performance, providing a basis for future improvements in data augmentation strategies and model optimization. Grad-CAM (Gradient-weighted Class Activation Mapping) interpretability analysis method was introduced to reveal the internal feature extraction process of the convolutional neural network in the frozen soil strength recognition task. It was found that the model could extract and analyze key image features of frozen soil, enabling rapid strength assessment. The research results provide a new approach for real-time monitoring of the frozen wall state and early disaster warning, offering technical support for the safe construction of freezing projects.

Key words: frozen soil; Uniaxial Compressive Strength (UCS); image recognition; transfer learning; model explainability analysis

0 引 言

人工冻结法是一种在岩土工程中得到广泛应用的施工技术,尤其在面临传统施工方法困难的地方,如难以支护的地下工程、矿山工程以及隧道工程等^[1]。这种方法的应用可以有效地建立坚实与稳定的冻结壁,能避免地下水的涌入并且在城市挖掘作业过程中有效控制邻近土层的变形。强度参数是评估冻结壁稳定性的最重要指标^[2]。只有及时准确获得这些参数,才能确保建设工程的安全性。

目前冻结壁在形成和维护期间的强度监测主要依赖传统的监测技术,如温度场监测^[3]。但单一的温度监测难以全面反映冻结壁强度的变化,特别是在复杂的冻结地层中,温度变化与强度变化并非实时对应,且冻土由于其起源和形成过程的不同,本质上是各向异性和非均质的^[4]。这种高度的多样性使得研究和预测行为变得困难。随着人工智能的发展和应用,其在岩土研究和工程实践中的应用也备受关注^[5]。人工智能算法具备自适应性、非线性建模能力以及高精度预测能力,能够弥补传统方法在处理复杂非线性问题中的局限性。

人工智能技术可以通过处理和分析大量的试验数据来发现其中隐藏的规律和模式,并依此建立模型预测冻土的力学性质。JALAL 等^[6]利用人工神经网络和基因表达式编程等方法建立了预测膨胀土压力和单轴抗压强度的模型,并验证了其可靠性。SOLEIMANI 等^[7]基于多基因遗传规划提出的模型能有效预测黏土的无侧限抗压强度,证实了其对多种参数的适应性。REN 等^[8]引入了基于鲸鱼优化算法的 El-

man 神经网络预测模型,有效地处理了超低温冻土抗压强度与影响因素之间的复杂非线性关系。LI 等^[9]、PHAM 等^[10]、WEI 等^[11]也同样实现了人工智能技术与冻土力学性质的结合。训练完成后的人工神经网络的实时性通常受到输入数据获取方式的限制。大多数机器学习模型仍依赖于温度、含水率等外部测试数据作为输入参数,而这些参数的获取通常需要借助专门设备进行现场测量或实验室测试^[12]。这种对外部参数的依赖性对于许多需要快速响应的应用场景,其效果可能会受到限制。

相比传统机器学习方法,基于深度学习的图像识别技术具有更优越的实时预测能力^[13]。一旦训练和部署完成,深度学习模型能够自动从输入图像中提取特征,并进行实时预测,提高了预测的准确性和效率,且无需依赖人工特征选择。HE 等^[14]提出了一种结合图像数据的深度卷积神经网络方法,通过对钻探性能参数生成的图像进行训练,快速、连续地估计岩石现场强度参数,预测精度误差在 10% 以内,且优于传统方法。HAN 等^[15]提出了一种基于深度卷积网络的光谱图分析方法,通过地质锤敲击岩石产生的光谱图作为输入,以 Inception-v3 模型为基础,实现了对岩石表面强度的预测。现有岩土强度参数的获取方法还有超声波^[16]和电阻率^[17]等无损监测方法。这些方法在应用场景中能够提供有效的监测数据,同时超声波和电阻率测量与强度参数之间的关系通常需要通过间接推断或模型转换来建立^[18]。在此背景下,图像识别技术为冻土强度监测和冻结壁状态判识提供了一种新的思路,能够通过分析图像特征参数实现快速、实时、准确地获取冻土强度信息。

本研究聚焦于图像数据驱动的冻土强度参数智能识别。在实验室条件下建立了不同类别的强度图像数据集, 利用迁移学习 ResNet-34 深度学习模型对图像进行识别, 对比分析模型在不同迭代次数(Epochs)下的训练性能, 并分析、验证在最佳性能下模型的准确性和科学性。在此基础上利用视觉可解释分析方法对训练后的模型的机理进行深入探究, 尝试揭示模型如何从图像中提取特征, 并基于这些特征做出准确的识别决策, 为实时判定冻结壁稳定性提供快速、高效的解决方案。

1 冻土图像数据集的建立

1.1 试验试样的制备

选择泥炭质土、淤泥质黏土、砂质黏土和砂土进行人工冻土单轴抗压试验。试验方案见表 1。试验过程中使用的 93 组冻土试样如图 1 所示。

表 1 人工冻土单轴抗压试验方案

Table 1 Uniaxial compressive test program for artificial frozen soil

组数	土质	温度/℃	含水率/%
1~21	泥炭质土	-10	22、25、28、31、
		-15	34、37、40
		-20	
22~51	淤泥质黏土	-10	15、17、19、21、23、
		-15	25、27、29、31、33
		-20	
52~72	砂质黏土	-10	15、17、19、21、
		-15	23、25、27
		-20	
73~93	砂土	-10	11、13、15、17、
		-15	19、21、23
		-20	

土样因其不同的组成、结构和物理性质, 呈现出各异的冻土特性。试验在-10、-15 和-20 ℃ 三种温度, 以及 11%~40% 的含水率下进行, 以探究这些因素对冻土力学性质的影响。在这些条件下, 冻土的物理和力学特性的变化为图像识别模型提供了多样化的学习样本, 帮助模型更准确地识别不同冻结状态下土样的强度特征, 从而提升预测的精度。

试验前将 4 种土壤样本置于自然环境下风干。随后这些样本被转移至预先加热至 105 ℃ 的烤箱中, 以确保其在至少 8 h 的时间里彻底干燥, 便于测定干土的质量, 并据此计算含水率(表 1)。为保证土壤样

本的均匀性, 土样在搅拌后被密封于塑封袋中, 以防水分散失。采用 3 层压缩法人工压实土壤, 加工成直径为 50 mm, 高度为 100 mm 的圆柱体试样。制备完成的试样连同模具一起被密封于塑料薄膜中, 并放置于低温冷冻箱中养护 3~6 h。养护完成后, 将试样从模具中取出。最终将所有试样分别放置于设定温度的低温冷冻箱中, 进行 24 h 的恒温养护。该流程旨在确保土壤样本在后续测试前达到理想的物理状态, 从而保证试验结果的准确性。

1.2 冻土图像采集方法

本次图像采集使用到的设备为尼康 D7500 数码单镜反光照相机。该设备的有效像素约为 2 088 万, 确保了图像质量的高清晰度。在图像采集过程中, 每制作并养护完成一个人工冻土试样时, 立即将其置于摄像机前, 使用 LED 灯补光, 调节光源亮度和镜头焦距, 待图像清晰后迅速拍摄。在采集试样的照片时, 从不同的角度和位置对试样进行抓拍, 以尽量覆盖其表面特征的多样性。这有助于全面捕捉试样的表面特征及其细节, 为后续的分析提供了高质量的图像数据。在图像采集完成后, 立即对试样进行单轴抗压强度试验。测试得到的峰值强度值将与图像数据进行标注, 如图 2 所示。

在-10、-15、-20 ℃ 的温度下, 对含水率 11%~40% 的试样进行单轴压缩试验。本次试验共制备了 93 个试样。将试样用保鲜膜密封包裹, 并贴上对应测试信息的标签。采用 WDT-100 型冻土试验机对试样进行单轴压缩试验, 应变速率设定为 10^{-2} min^{-1} , 试验结束条件设置为应力下降 20% 或应变超过 15%。微机每 15 s 自动采集数据并显示相应的应力-应变曲线, 并记录试样的单轴抗压强度。由于篇幅限制, 仅展示出淤泥质黏土 30 组试样的应力-应变曲线, 如图 3 所示。可以看出淤泥质黏土的整体强度随着温度的降低而增大。

不同冻土试样抗压强度的数据分布如图 4 所示。根据图 4 中不同冻土试样在强度上的差异和各自数据分布特点的分析可得: 泥炭质土的强度变化较大, 但大部分数据集中在 6 MPa; 淤泥质黏土和砂质黏土的强度数据分布有着类似的特点, 它们的数据主要聚集在 3 MPa 左右; 砂土的强度分布集中在 4 MPa 左右。

1.3 图像数据集的建立与维护

深度学习的图像识别技术是利用深度神经网络, 尤其是卷积神经网络(CNN)来解析和理解图像内容的一系列方法和技术。而图像分类是其最基础、广泛、成熟的应用之一。为了充分利用深度学习在分类任务上的优势, 以进行人工冻土单轴抗压强度的识别,

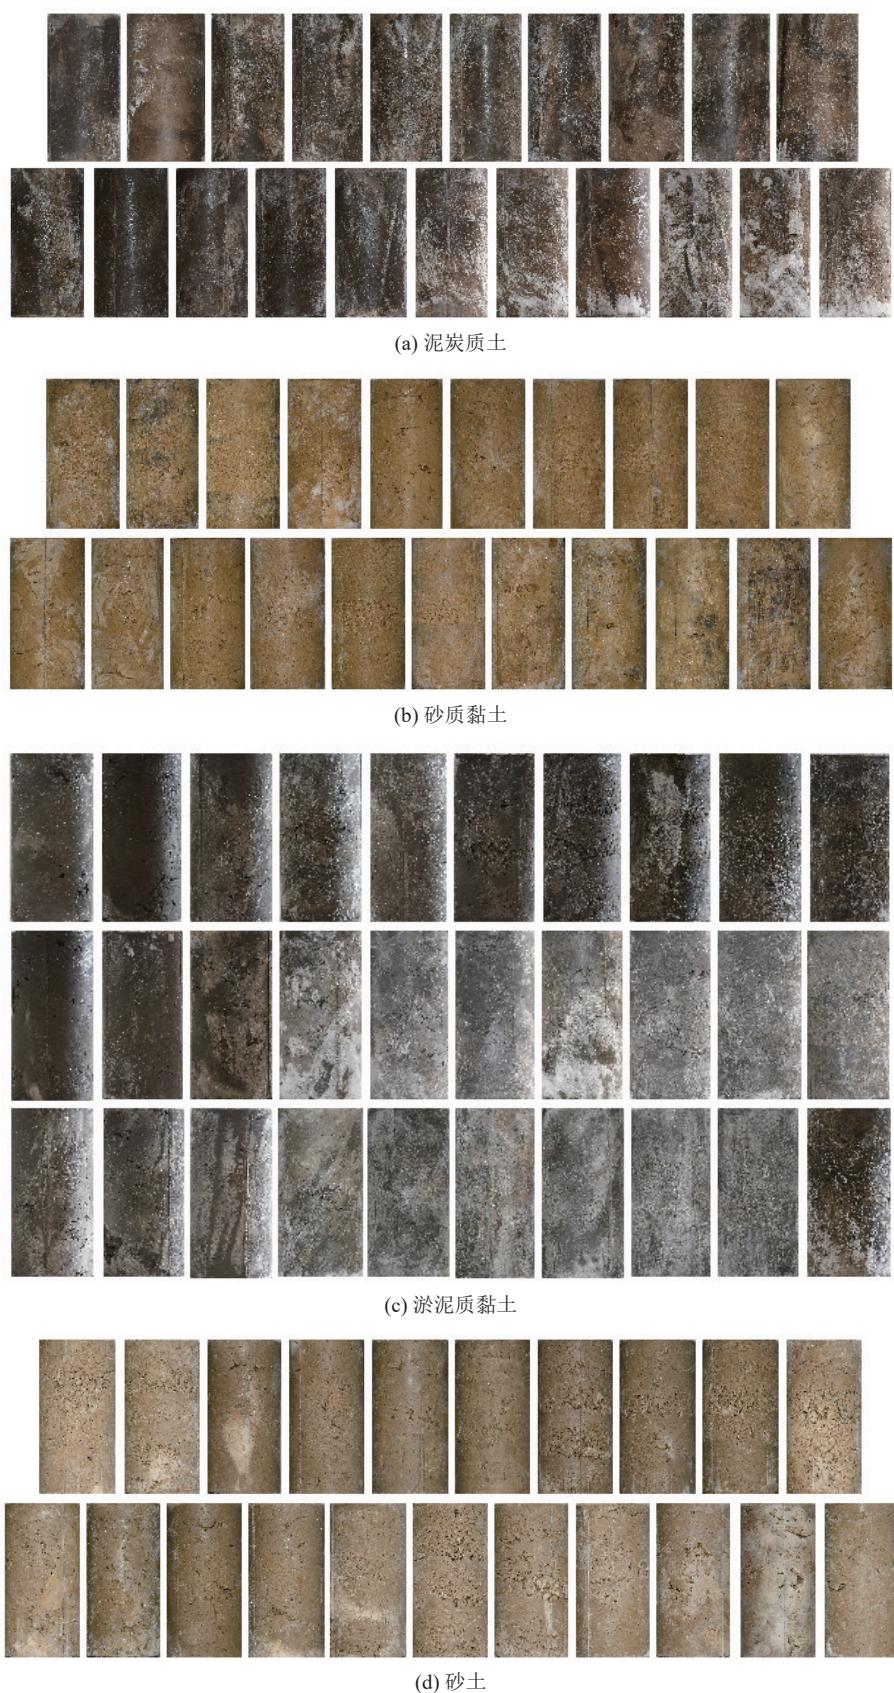


图 1 试验 93 组试样

Fig.1 Test 93 groups of specimens

本研究拟采用基于 CNN 的方法, 依据其单轴抗压强度 (UCS) 将人工冻土样本归入不同的类别中。尽管

理论上可以通过定义无限多的类别来模拟 UCS 的连续值分布, 但由于深度学习中的多类分类问题实际上

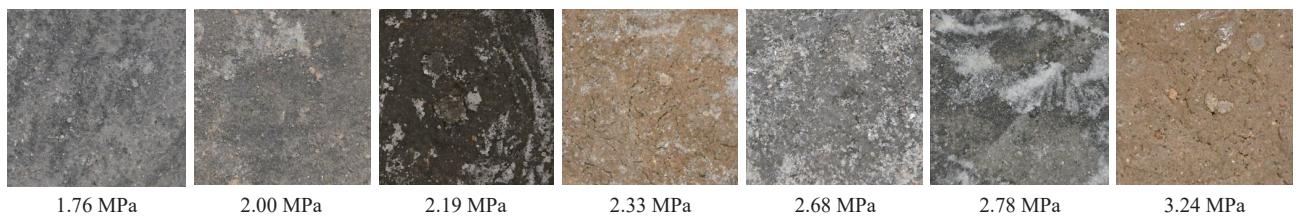


图2 部分图像数据及其峰值强度标注
Fig.2 Partial image data and its peak intensity labeling

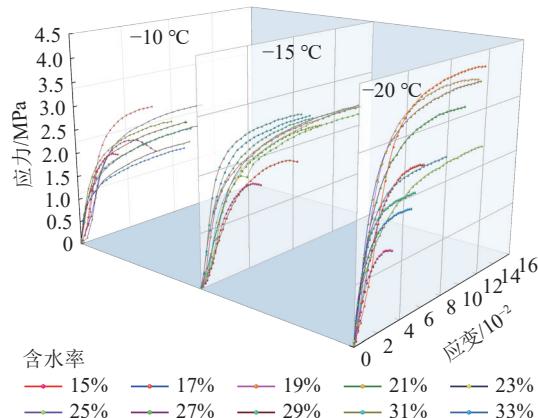


图3 淤泥质黏土的应力-应变曲线
Fig.3 Stress-strain curves of silty clay soil

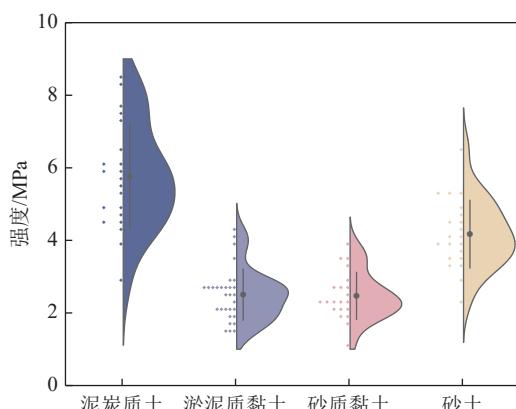


图4 不同冻土试样抗压强度的数据分布
Fig.4 Data distribution of compressive strength

基于有限类别,故将 UCS 的连续值划分为若干离散区间,每个区间对应一个类别,从而将连续数据转化为分类问题进行处理。由于实际试验中的样本分布不均衡,考虑对强度范围进行了非等宽划分,以更好地反映数据的实际分布。这种划分方式使模型在训练过程中能获得更具代表性的样本,避免数据不平衡影响模型性能。在中等抗压强度区间采用较小的区间范围(如 2.6~2.7 MPa),以提高精度;而在抗压强度变化较大区间,适当扩大范围(如 0.5 MPa),以保证样本的充分性和模型的稳定性。

为了尽可能保证数据集分类的精度和样本的均衡性,考虑舍去过大和过小的抗压强度,得到强度的

不同范围及其标签和分类见表2。

表2 数据集的不同类别

Table 2 Different categories of the dataset

类别标签	抗压强度/ MPa	试样 样本数	类别标签	抗压强度/ MPa	试样 样本数
1	1.7~2.0	7	7	2.9~3.4	5
2	2.0~2.1	6	8	3.4~3.8	6
3	2.1~2.3	5	9	3.8~4.1	8
4	2.3~2.6	8	10	4.1~4.6	8
5	2.6~2.7	5	11	4.6~5.0	5
6	2.7~2.9	9	12	5.0~5.4	5

根据表2得到的数据集类别,将采集到的人工冻土图像整理归档,分别放入12个子文件夹中进行标注。为避免某些类别图像数量不足影响模型的分类能力,通过对每个子文件夹中的图片进行旋转、裁剪和缩放等数据增强处理,将每个类别的图像数量扩展至200张,最终得到总共2 400张的图像数据集。再利用Python程序将数据集中的图像随机划分为训练集和测试集。数据集的划分采取了80%的样本用于训练,20%的样本用于测试。该划分比例能确保模型在训练过程中充分学习,同时保留足够的数据用于验证模型的泛化能力。具体为训练集包含约1 920张图像,而测试集则包含约480张图像。

2 基于卷积神经网络的模型搭建

在近年来,以卷积神经网络(CNN)为代表的深度学习技术和计算能力的显著进步,已经极大地促进了自动特征提取技术的发展。这种进步提供了一种更为高效且有效的方式来处理和分析图像数据^[19]。

2.1 卷积神经网络

经典的CNN模型首先在输入层接收冻土图像数据,通常是由像素值组成的矩阵。通过应用一系列滤波器(也称为卷积核)对输入图像进行卷积操作,提取图像的特征。每个滤波器会检测图像中的特定模式或特征,例如颗粒大小、纹理和冰晶等。对卷积层的输出进行非线性变换,以引入非线性特性。再进入池

化层,减少特征图的空间维度,降低计算复杂度,同时提取出特征的主要信息。接着来到全连接层,将经过卷积和池化的冻土特征图展平为一维向量,并通过全连接层将其与输出层连接,进行分类任务。最后输出网络对输入图像的预测结果,通常使用 softmax 函数

进行分类问题中的概率分布预测。通过不断优化参数和结构,CNN 能够有效地从冻土的图像数据中提取特征,并在识别强度任务中取得优异的性能。本研究使用的卷积神经网络结构为 ResNet-34 网络,其特征提取结构和工作流程如图 5 所示。

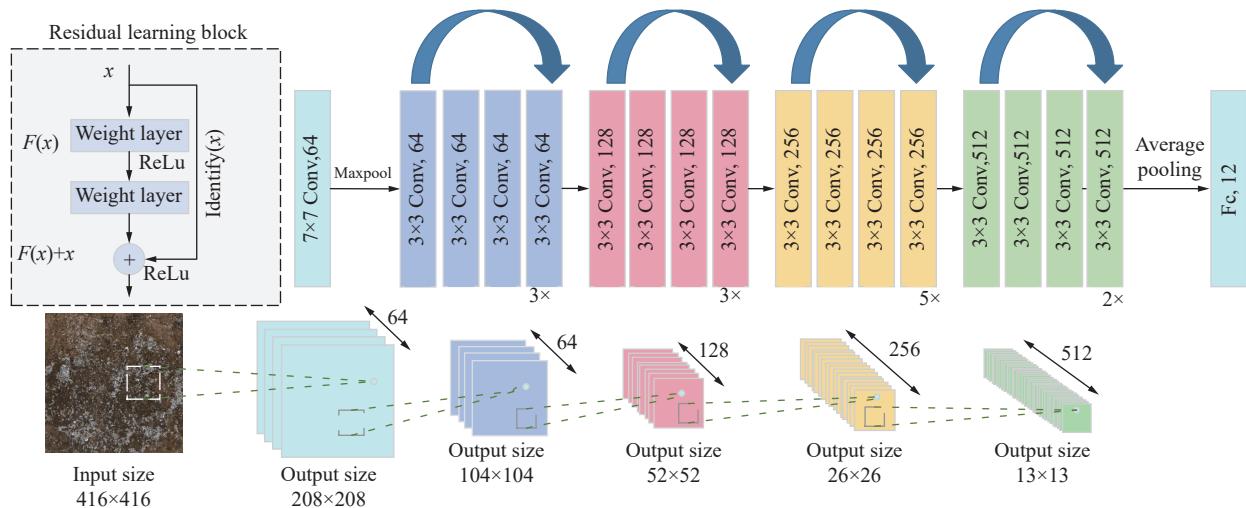


图 5 ResNet-34 网络结构

Fig.5 Structure of ResNet-34 network

2.2 迁移学习神经网络

在图像分类任务中,卷积神经网络模型已经证明了其卓越的性能,尤其是在 ImageNet 这一大规模图像数据集上的应用,其中 CNN 模型通过大量训练,成功学习了对图像分类至关重要的广泛特征。鉴于此,迁移学习的策略提供了一种高效的方法,允许研究者利用已经在 ImageNet 数据集上预训练的经典 CNN 模型的丰富先验知识^[20]。通过精细地调整预训练模型的特定层次结构和参数,可以对模型进行优化和微调,从而适应于特定的应用场景,如人工冻土单轴抗压强度的智能识别。

如图 6 所示,预训练模型在原始任务上已经学会部分特征如冰晶、土的颜色和颗粒大小。通过迁移学习方法可以使深度学习模型更快地收敛。这种方法

不仅显著降低了从零开始训练模型所需的数据量和计算资源,同时也提高了模型在特定任务上的性能和泛化能力。

2.3 改进 ResNet-34 结构

深度残差网络(ResNet)是微软研究院的 HE 等^[21]在 2015 年提出的深度学习模型,它在 ImageNet 竞赛中取得了优异的成绩。ResNet 通过引入“残差连接”解决了深层网络训练难的问题。ResNet 系列包括不同深度的模型,其中 ResNet-34 找到了卓越性能和低复杂性之间的理想平衡,使其成为许多图像分类任务中的首选模型。

原始的 ResNet-34 网络 softmax 层的分类个数为 1 000,网络最后通过一个全连接层增加网络分类性能,结构为[512,1 000]。最后的全连接层输入来自前一层



图 6 迁移学习示意

Fig.6 Schematic diagram of transfer learning

的池化层, 共有 512 个神经元, 因此全连接层训练需要 51 300 个参数。对于冻土强度分类任务, 分类类别数为 12, 原始 ResNet-34 网络的全连接层参数过多, 并不能提高模型的准确率。因此, 本文对 ResNet-34 网络的全连接层进行了改进。将原始结构改进为 [512, 12], 改进后的全连接层参数只有 6 156 个, 更适用人工冻土强度识别任务。在配制模型的超参数时, Batch Size 是指每次输入模型进行训练的数据样本数量, 取为 64, 优化函数选取 Adam 优化器, 损失函数选择交叉熵损失函数^[22]。对于深度学习来说, 计算机配置和开发环境都是极为重要的。本文模型搭建的计算机配置和开发环境见表 3。

表 3 模型搭建的开发环境

Table 3 Development environment for model building

软/硬件	型号与版本
操作系统	Windows 10 64位
处理器	AMD Ryzen 7 5800H
内存	16 GB
显卡	Nvidia GeForce RTX 3060
编程语言	Python 3.10.9
深度学习框架	PyTorch 2.0.1

3 智能模式识别及验证

基于已搭建完成的深度学习模型, 对冻土的强度进行智能识别, 并对识别结果进行深入分析, 对冻土的特征识别进行验证。

3.1 冻土强度识别结果

在初始试验中, 通过试验验证多种批量大小 Batch Size(如 32、64、128), 确认 Batch Size 为 64 时模型的训练速度和性能表现最佳。表 4 为不同 Batch Size 对模型准确率和平均训练时长的影响。

表 4 不同批量大小下测试集的分类结果评价

Table 4 Evaluation of classification results of test set under different Batch Size

批量大小	准确率/%	迭代1次的平均训练时长/s
32	87.9	36.23
64	92.8	45.07
128	90.3	51.33

在深度学习中, Epochs 为模型完整遍历整个数据集的次数。通常情况下, 随着 Epochs 的数量增加, 模型的性能会逐渐提升, 直到收敛到最优解。选择不同的 Epochs 进行训练, 找到使模型在测试集上表现最

好的 Epochs 数量, 这有助于避免过拟合或欠拟合。

依据图 7 不同 Epochs 下的训练曲线可知, 当 Epochs 为 50 和 100 时, 损失函数还未收敛, 且呈现继续下降的趋势, 模型未达到最佳性能。在 Epochs 达到 150 和 200 时, 损失逐渐收敛, 且达到了最佳性能。但通过测试集的准确率对比, Epochs 为 150 时的准确率更高。随着训练轮次的增加, 模型可能会记住训练数据中的噪声和特定样本的特征, 而不是学到普遍的模式和规律。由表 5 可知, Epochs 为 150 时, 其测试集的 3 个分类指标都是最高的。所以选择保存 150 个 Epochs 的 ResNet-34 模型权重文件, 以便后续深入研究。

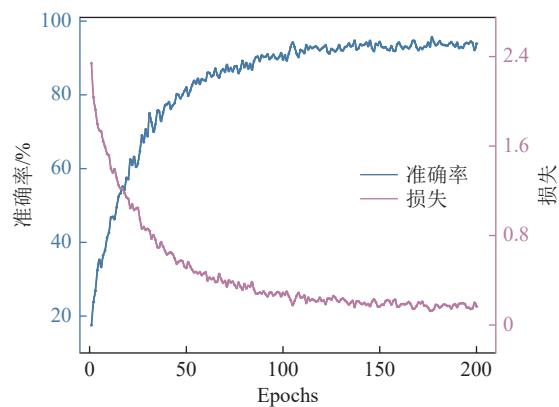


图 7 模型训练集在不同 Epochs 下的训练结果

Fig.7 Training results of model training set under different Epochs

表 5 不同 Epochs 下测试集的分类结果评价

Table 5 Evaluation of classification results of test sets under different Epochs

Epochs	准确率/%	召回率/%	F ₁
50	71.0	69.6	0.692
100	82.5	82.5	0.825
150	92.8	92.5	0.926
200	89.0	88.3	0.882

注: F₁ 为精确率和召回率的调和平均数。

为了验证所选模型的有效性, 对比 ResNet-18 和 ResNet-50 网络。在相同的数据集和训练配置下, 分别对 ResNet-18、ResNet-34 和 ResNet-50 进行训练, 以确保比较的公平性。所有模型的超参数设置一致, 包括学习率、批次大小和训练轮数。为了进一步验证深度网络相较于传统卷积神经网络的优势, 引入 AlexNet 模型进行对比。通过与 AlexNet 的性能比较, 可以更清晰地展示深度残差网络在冻土强度识别中的潜力和优势。得到不同模型的性能指标见表 6, 结

结果显示 ResNet-34 在 3 个分类指标的效果依然是最好的。

表 6 不同模型测试集的分类结果评价

Table 6 Evaluation of classification results for different model test sets

迁移网络模型	准确率/%	召回率/%	F_1
AlexNet	46.67	46.7	0.459
ResNet-18	91.04	91.0	0.910
ResNet-34	92.80	92.5	0.926
ResNet-50	86.25	86.3	0.862

图 8 展示的混淆矩阵是 150 个 Epochs 的 ResNet-34 模型在测试集的性能表现。混淆矩阵是一个非常有用的工具, 用于衡量分类模型的准确性, 其中每一行代表真实的类别, 每一列代表模型预测的类别。在这个特定的矩阵中, 沿对角线的数字表示模型预测正确的数据点数量, 非对角线上的数字表示预测错误的数据点数量。矩阵的颜色深浅代表数量的多少, 颜色越深表示数量越多。

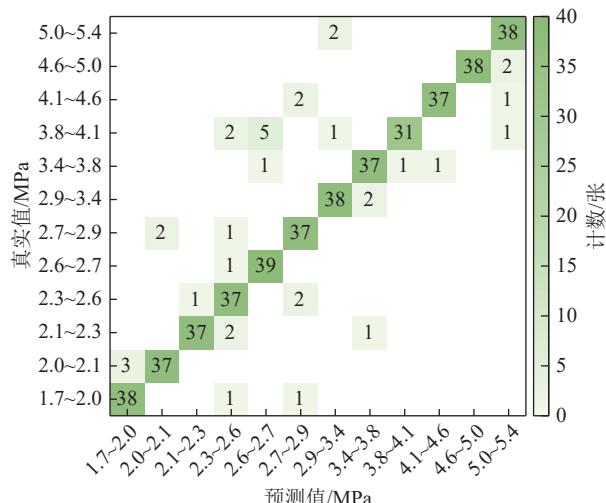


图 8 真实值与预测值之间的混淆矩阵

Fig.8 Confusion matrix between true and predicted values

根据混淆矩阵结果, 测试集包含 480 张冻土强度图片, 其中 444 张被正确识别。深度学习模型在 2.6~2.7 MPa 类别的预测效果最佳, 正确识别 39 张图片, 唯一的误分类发生在相邻类别 2.3~2.6 MPa。3.8~4.1 MPa 类别的预测效果最差, 正确识别了 31 张图片。大多数数据点集中在对角线上, 表明模型在多数情况下能够准确预测类别。

3.2 冻土强度特征识别的验证

研究人工冻土的单轴抗压强度时, 识别和理解影响强度的关键因素至关重要。利用 CNN 强大的图像识别和特征提取能力, 可以从冻土图像中识别出这些

关键因素的视觉特征。CNN 模型可被训练识别图像中与土质粒度、含水量变化及温度差异相关的特定模式和纹理。一旦模型识别出这些模式并将其与试验数据关联, 就可为预测冻土抗压强度提供坚实基础。

利用深度学习模型对人工冻土单轴抗压强度的影响因素土质、温度和含水率进行识别, 得到结果如图 9 所示。为进一步清晰展示特征识别结果, 汇总情况见表 7。

依据图 9a 能看出 CNN 模型在土质变量的识别上表现优异, 准确率普遍超过 95%。模型能够自动提取与土质相关的关键特征, 例如土壤的颜色、纹理以及颗粒尺寸, 证明了其在处理土质识别任务时的高效性。

进一步分析图 9b 可以判断 CNN 模型也可以较好地识别出温度变量, 准确率接近 90%。随着温度的降低, 冻土表面的颜色可能会变得更加淡白, 这是因为水分结冰导致冰晶的反射增加。在一些情况下, 表面可能会出现霜花或冰晶的结构。CNN 模型通过学习和提取这些图像特征, 有效地识别温度变化的影响。

从图 9c 可以看出, CNN 模型对含水率的识别准确率约为 83%, 略低于土质和温度。这可能是由于冻土含水率的变化在图像中较为微妙, 特别是在冻结过程中水分以冰的形式存在时, 这种变化在视觉上难以清晰呈现。尽管如此, CNN 模型整体识别效果依然较好。通过准确识别这 3 个变量, 验证了冻土强度识别方法的可靠性。

3.3 扰动场景对模型预测性能的影响分析

在实际冻结工程施工中, 获取的图像数据常受到不同环境因素的影响, 与室内试验条件存在显著差异。为评估模型在复杂场景下的适用性和可行性, 考虑模拟典型干扰场景并分析其对模型预测性能的影响。

在已有的图像数据集中选取一张图像进行模拟场景处理, 包括低光照模拟、模糊效果以及局部遮挡。模拟现实施工环境中可能遇到的情况, 例如现场光线不足, 设备移动导致的图像动态模糊以及镜头或目标表面的污渍。经过模拟处理后的图像如图 10 所示。

利用前文训练好的深度学习模型预测经过模拟处理后的图像数据并分析误差。选择的原始图像类别为 2.6~2.7 MPa, 而图像经过亮度、对比度降低后的预测结果为 2.7~2.9 MPa, 经过动态模糊和部分遮挡后的预测结果为 2.6~2.7 MPa。分析可以看出在亮度降低和对比度降低的情况下, 模型未能准确预测, 与真实结果为相邻类别。这可能是因为图像亮度和对比度变化可能导致关键特征(如冰晶分布或裂缝)的可见性降低, 影响模型的特征提取能力。在动态模糊和部分遮挡的情况下, 模型能够正确预测类别。这

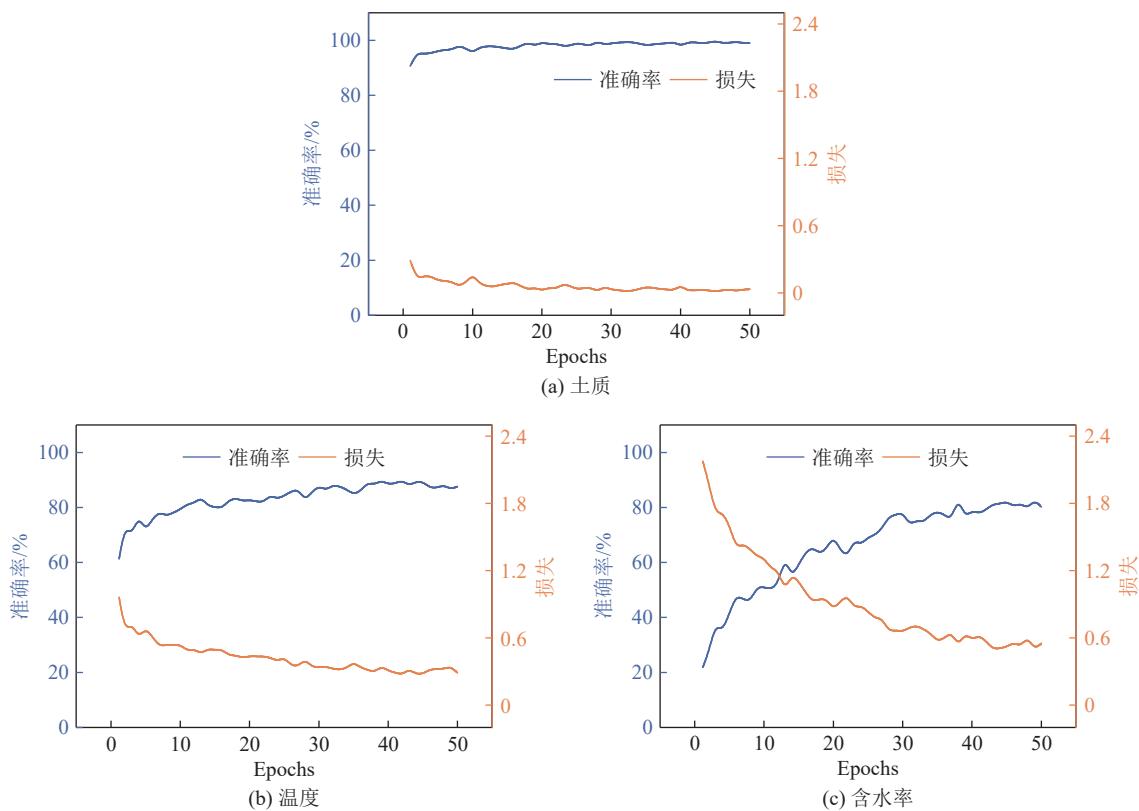


图9 冻土特征提取的训练结果

Fig.9 Training results for permafrost feature extraction

表7 不同影响因素的特征识别结果

Table 7 Results of feature identification for different influencing factors

影响变量	关键特征	准确率/%
土质	颜色、纹理以及颗粒尺寸	99.7
温度	冰晶形态和分布	89.3
含水量	颜色、纹理及冰晶形态和分布	82.6

可能是因为动态模糊和部分遮挡未显著破坏关键特征区域,使得模型仍能提取有用特征。还有一种情况是训练数据可能包含类似模糊或遮挡特征的样本,增强了模型的鲁棒性。

通过研究模型在不同干扰条件下的表现,为后续改进数据增强策略和模型优化方向提供依据。在未

来研究将采集实际冻结壁施工环境数据,以评估模型在不同条件下的预测性能,并通过扩展数据集多样性和融合多模态数据(如超声波、电阻率)来增强模型的泛化能力和预测精度。

4 深度学习模型解释性分析

鉴于深度卷积神经网络在特征提取过程中呈现出的高度抽象性,其内部逻辑和决策过程在语义层面上常常难以直接理解,这导致了深度卷积神经网络在很大程度上被开发者和研究人员视为“黑盒子”模型^[23]。ZHOU等^[24]提出了类激活映射(Class Activation Mapping, CAM)技术。该技术能够生成类似于热力图的可视化结果,揭示了模型在进行决策时对图像哪些部分给予了更多的关注。但其受限于特定

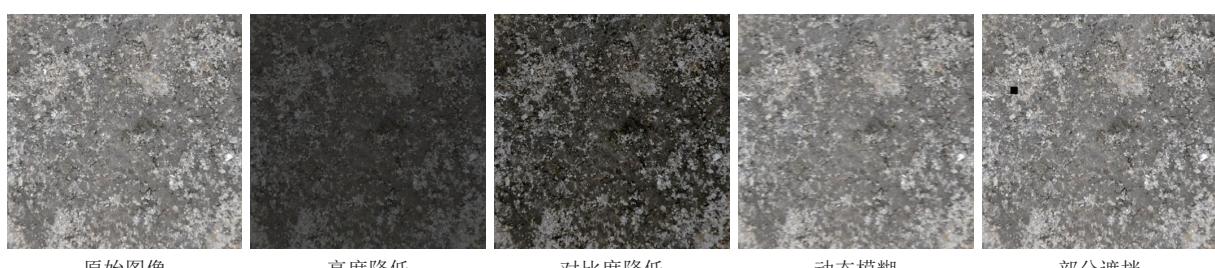


图10 模拟场景处理下的图像数据

Fig.10 Image data under simulated scene processing

模型结构且可能丢失细节, SELVARAJU 等^[25]进一步发展了 Grad-CAM(Gradient-weighted Class Activation Mapping)方法。该技术利用梯度信息加权特征图,适用于更多 CNN 架构并在保留更多细节方面提供了更精确的模型解释。

为了探究深度学习模型识别试样的原理与逻辑,采用 Grad-CAM 方法对冻土强度的识别进行分析,得到关键区域的热力图,并将热力图进行重新采样与原图融合的方式进行展示。冻土具有独特的物理和化学特性,这些特性在图像中表现为特定的纹理、颜色和冰晶分布。

Grad-CAM 方法可以帮助识别深度学习模型依赖于哪些特定的图像特征来识别冻土的不同属性。例如,模型可能依赖于特定的纹理来区分冻土的不同类型或识别冻土的强度等级。其中热力图采用的是热成像图,颜色会随着能量的升高而变红,随着能量的减少而变蓝,红色越深表示模型对该部分越关注,对识别结果的影响越大,蓝色越深则相反。

由前文得到 2.6~2.7、2.0~2.1、3.8~4.1 MPa 三个类别的预测准确率依次降低。图 11 显示,模型关注区域较大的图像,其对应的强度识别准确率更高。这可能是因为在“2.6~2.7 MPa”类别中,模型的关注区域更大,能够提取更多有效特征,从而实现最高的识别精度。关注区域较大意味着模型能够从图像中捕捉到更多的特征信息,这些信息可能包括强度相关

的关键视觉特征,如裂缝、颗粒结构、孔隙分布等。当模型能够基于更多的信息进行推断时,预测的准确性自然会提高。

土质决定了冻土的基本结构和性质,是影响其强度的关键因素。以土质为例,模型分析结果如图 12 所示,可以看出砂质黏土的模型关注区域面积占比最大为 61.22%,砂土次之为 57.14%,淤泥质黏土的关注区域占比为 51.02%,泥炭质土的关注区域最小。土壤类型主要通过其纹理和颜色来区分。砂质黏土通常含有较大颗粒和明显的纹理特征,便于模型识别和锁定。砂土因颗粒较大,可能产生更多影像特征,如明显的颗粒边界,模型更易识别。淤泥质黏土和泥炭质土颗粒细小,纹理较为均匀,难以被模型区分,因此关注区域较小。不同土质的强度各异,模型通过识别土质可更准确锁定土样强度范围,从而实现冻土强度的精确识别。

5 结 论

1) 通过对不同深度学习模型在强度图像数据集的识别效果,发现 ResNet-34 模型识别效果最好,准确率为 92.8%,说明卷积神经网络能够较好地识别人工冻土的强度。

2) 利用深度学习模型对人工冻土强度的影响因素土质、含水率和温度进行识别,验证模型在提取和识别这些特征方面的能力,发现深度学习模型都能很

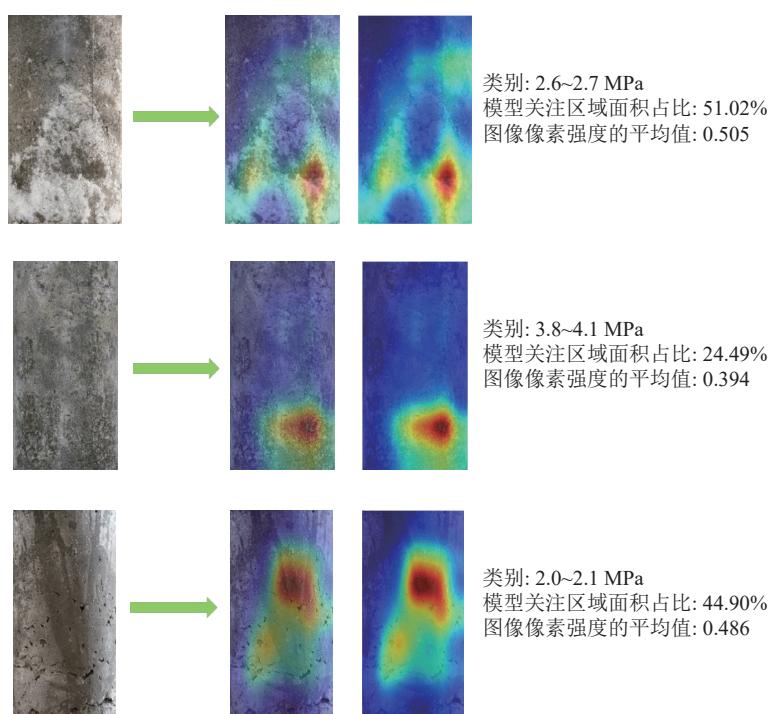


图 11 不同类别热力融合对比

Fig.11 Comparison of different categories of heat fusion maps

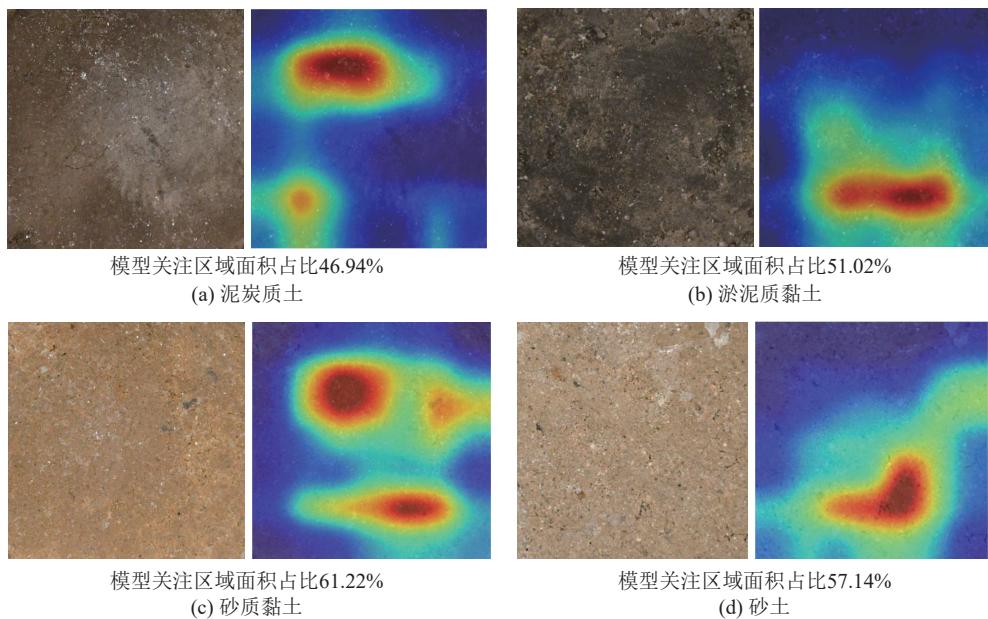


图 12 不同土质下的热力

Fig.12 Thermal maps for different soil textures

好地识别这3个影响因素。

3) 模拟典型干扰场景并分析其对模型预测性能的影响,发现模型在这些场景下的鲁棒性较好。通过视觉可解释性分析对训练后的模型的机理进行了探究。引入Grad-CAM方法进行分析,结果表明模型关注区域越大的类别能够提取的有效特征越多,该类别准确率越高。

参考文献(References):

- [1] 陈瑞杰,程国栋,李述训,等.人工地层冻结应用研究进展和展望[J].岩土工程学报,2000,22(1): 43–47.
CHEN Ruijie, CHENG Guodong, LI Shuxun, et al. Development and prospect of research on application of artificial ground freezing[J]. Chinese Journal of Geotechnical Engineering, 2000, 22(1): 43–47.
- [2] 陈维健,周晓敏,乔卫国.大水流地层条件下井筒冻结壁动态监控理论和技术[J].煤炭学报,2008,33(9): 1006–1010.
CHEN Weijian, ZHOU Xiaomin, QIAO Weiguo. Monitoring theory and technology of freeze wall in shaft sinking of heavy seepage ground[J]. Journal of China Coal Society, 2008, 33(9): 1006–1010.
- [3] 焦华喆,孙冠东,陈新明,等.深厚冲积层多圈孔冻结壁温度场发展研究[J].煤炭学报,2018,43(S2): 443–449.
JIAO Huazhe, SUN Guandong, CHEN Ximeng, et al. Study on the development of temperature field of frozen wall with multiple holes in deep alluvium[J]. Journal of China Coal Society, 2018, 43(S2): 443–449.
- [4] YIN Z Y, JIN Y F, LIU Z Q. Practice of artificial intelligence in geotechnical engineering[J]. Journal of Zhejiang University: Science A, 2020, 21(6): 407–411.
- [5] 薛生,郑晓亮,袁亮,等.基于机器学习的煤与瓦斯突出预测研究进展及展望[J].煤炭学报,2024,49(2): 664–694.
XUE Sheng, ZHENG Xiaoliang, YUAN Liang, et al. A review on

coal and gas outburst prediction based on machine learning[J]. Journal of China Coal Society, 2024, 49(2): 664–694.

- [6] JALAL F E, XU Y F, IQBAL M, et al. Predictive modeling of swell-strength of expansive soils using artificial intelligence approaches: ANN, ANFIS and GEP[J]. Journal of Environmental Management, 2021, 289: 112420.
- [7] SOLEIMANI S, RAJAEI S, JIAO P C, et al. New prediction models for unconfined compressive strength of geopolymers stabilized soil using multi-genetic programming[J]. Measurement, 2018, 113: 99–107.
- [8] REN Z F, WANG E L, LIU J K, et al. Characterization and prediction of compressive strength in ultralow-temperature frozen soil using nuclear magnetic resonance and WOA-ENN Model[J]. Transportation Geotechnics, 2023, 43: 101143.
- [9] LI K Q, YIN Z Y, ZHANG N, et al. A data-driven method to model stress-strain behaviour of frozen soil considering uncertainty[J]. Cold Regions Science and Technology, 2023, 213: 103906.
- [10] PHAM B T, SON L H, HOANG T A, et al. Prediction of shear strength of soft soil using machine learning methods[J]. Catena, 2018, 166: 181–191.
- [11] WEI M D, MENG W Z, DAI F, et al. Application of machine learning in predicting the rate-dependent compressive strength of rocks[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(5): 1356–1365.
- [12] 陈湘生,曾仕琪,韩文龙,等.机器学习方法在盾构隧道工程中的应用研究现状与展望[J].土木与环境工程学报(中英文),2024,46(1): 1–13.
CHEN Xiangsheng, ZENG Shiqi, HAN Wenlong, et al. Review and prospect of machine learning method in shield tunnel construction[J]. Journal of Civil and Environmental Engineering, 2024, 46(1): 1–13.
- [13] 蒋树强,闵巍庆,王树徽.面向智能交互的图像识别技术综述与展

- 望[J]. *计算机研究与发展*, 2016, 53(1): 113–122.
- JIANG Shuqiang, MIN Weiqing, WANG Shuhui. Survey and prospect of intelligent interaction-oriented image recognition techniques[J]. *Journal of Computer Research and Development*, 2016, 53(1): 113–122.
- [14] HE M M, ZHANG Z Q, REN J, et al. Deep convolutional neural network for fast determination of the rock strength parameters using drilling data[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2019, 123: 104084.
- [15] HAN S, LI H, LI M C, et al. Measuring rock surface strength based on spectrograms with deep convolutional networks[J]. *Computers & Geosciences*, 2019, 133: 104312.
- [16] 郑天斌. 超声波检测在副斜井井壁质量探查中的应用[J]. 煤炭工程, 2019, 51(12): 19–23.
- ZHENG Tianbin. Application of ultrasonic testing technology in side wall quality detection of auxiliary inclined shaft[J]. *Coal Engineering*, 2019, 51(12): 19–23.
- [17] 王桦. 矿山岩土体导电特性及工程应用研究[D]. 淮南: 安徽理工大学, 2009.
- WANG Hua. Study on electrical conduction characteristic of rock-soil masses in mines and its application to engineering[D]. Huainan: Anhui University of Science & Technology, 2009.
- [18] 张基伟, 刘志强, 单仁亮, 等. 复杂地层井筒冻结壁异常状况监测技术研究现状与展望[J]. 煤炭科学技术, 2019, 47(1): 103–109.
- ZHANG Jiwei, LIU Zhiqiang, SHAN Renliang, et al. Review and prospect of abnormal condition of shaft frozen wall monitoring technique in complex formation condition[J]. *Coal Science and Techno-*
logy
- [19] TIAN Y H. Artificial intelligence image recognition method based on convolutional neural network algorithm[J]. *IEEE Access*, 2020, 8: 125731–125744.
- [20] ZHUANG F, QI Z, DUAN K, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2020, 109(1): 43–76.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2016: 770–778.
- [22] 张晗, 魏文龙, 刘森森, 等. 基于迁移卷积神经网络的黄土含水率智能识别[J]. 工程地质学报, 2023, 31(1): 21–31.
- ZHANG Han, WEI Wenlong, LIU Sensen, et al. Intelligent identification method of moisture content of loess based on transfer convolutional neural networks[J]. *Journal of Engineering Geology*, 2023, 31(1): 21–31.
- [23] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//Computer vision–ECCV 2014. Cham: Springer International Publishing, 2014: 818–833.
- [24] ZHOU B L, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2016: 2921–2929.
- [25] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2017: 618–626.