

DOI: 10.11779/CJGE20221516

基于搜索分析深度学习网络(SaNet)的粗粒土级配识别

庞元恩, 石国栋, 段煜, 姚敏, 吉浩泽, 罗鸣, 李茂彪, 李旭*

(北京交通大学城市地下工程教育部重点实验室, 北京 100044)

摘要: 粗粒土广泛应用于路基、土石坝等填方工程中, 然而传统筛分法耗时低效, 无法满足级配快速的质量检测需求。为解决上述问题, 构建了黄河粉土、石英砂粗粒土“图像-级配”关系数据库, 共 22380 张图像; 针对二维图像与三维级配的不匹配的矛盾, 构建了任意图像输入数量的搜索-分析网络 (searcher-analyzer network, SaNet), 基于该网络训练所得模型精度随图像数的增加稳定提升, 黄河粉土, 石英砂的级配识别平均误差分别为 1.63%, 1.21%, 拟合优度分别为 0.995, 0.992。结果表明: 基于 SaNet 架构构建的机器学习模型具有较高的级配识别精度, 能够满足填方工程中实时无损的级配检测需求。

关键词: 粗粒土; 级配; 卷积神经网络; 搜索-分析网络; 深度学习; 图像识别

中图分类号: TU411

文献标识码: A

文章编号: 1000-4548(2024)09-1984-10

作者简介: 庞元恩(2002—), 男, 学士, 主要从事机器学习在岩土工程应用等方面研究。E-mail: yuanenpang@gmail.com。

Gradation recognition of coarse-grained soil based on searcher-analyzer deep learning network (SaNet)

PANG Yuanen, SHI Guodong, DUAN Yu, YAO Min, JI Haoze, LUO Ming, LI Maobiao, LI Xu

(Key Laboratory of Urban Underground Engineering of Ministry of Education, Beijing Jiaotong University, Beijing 100044, China)

Abstract: The coarse-grained soil is widely used in embankments, earth-rock dams and other fill projects. However, the traditional sieving method is time-consuming and inefficient, failing to meet the rapid quality testing requirements for gradation. To address these issues, an "image-gradation" relational database is established for yellow river silt and quartz sand coarse-grained soil, comprising 22380 photos. In response to the mismatch between two-dimensional image and three-dimensional gradation, a searcher-analyzer network (SaNet) is developed to handle any number of image inputs. The model accuracy steadily improves with an increase in the number of images, with average errors of 1.63% and 1.21% for the recognition of yellow river silt and quartz sand gradations, and the coefficient of determination of 0.995 and 0.992, respectively. The results demonstrate that the proposed deep learning model on the SaNet architecture exhibits high accuracy in gradation recognition, meeting the real-time non-destructive gradation detection requirements in fill projects.

Key words: coarse-grained soil; gradation; convolutional neural network; searcher-analyzer network; deep learning; image recognition

0 引言

粗粒土是填方工程中常用的一种填料, 广泛用作城市道路、高速铁路的路基填筑及土石坝坝体的施工^[1-5]。粗粒土的级配好坏直接决定工程质量, 快速、高精度地进行粗粒土的级配检测具有极高的工程需求, 对填方工程中的土料质量控制至关重要。然而现阶段级配检测主要采用筛分法^[6], 该方法耗时低效, 无法满足级配的实时检测需求, 制约了填方工程自动化的进一步发展。因此, 开发一种速度快、精度高的级配识别方法对于填方工程质量控制具有重要意义。

近年来, 基于图像的级配识别方法因实时无损、

成本低廉的优点受到众多学者的关注。目前基于图像的级配识别方法主要有: ①基于边缘检测的数字图像分析方法^[7-10]; ②基于卷积神经网络的人工智能方法^[11-13]。方法①不需要构建庞大的数据集, 实现过程具有很强的可解释性。然而由于复杂成像以及黏连颗粒的问题, 该方法精度长时间以来难以进一步突破。方法②通过 CNN 模型自动提取图像特征, 依靠数据驱动实现更高精度的级配识别, 如 Fan 等^[11]基于改进的 MASK

基金项目: 国家重点研发计划项目 (2022YFE0200400)

收稿日期: 2022-12-07

*通信作者 (E-mail: cexuli2012@163.com)

R-CNN (mask region-based convolutional neural network) 实现对堆石料中每个颗粒的分类与定位, 接着通过外接多边形划分粒径范围, 最后将面积占比换算为质量占比得到级配曲线。刘禹杉等^[12]将上述方法应用到土石坝料级配识别上, 并提出了表层识别向空间转换的修正方法, 改善了级配识别精度。Zhou 等^[13]对 U-Net 进行了改进, 将其应用于 TBM 碴片级配识别, 即使在碴片与淤泥混合、碴片互相堆叠情况下, 深度学习模型也能很好地工作。虽然上述研究充分证明了 CNN 模型在复杂条件下提取颗粒特征的优越性, 但所用方法本质上是语义分割^[14], 需要在像素层面人为地标注所有堆料, 这对于颗粒多、粒径小的粗粒土而言是不可能的。目前级配识别方法难以突破的主要原因在于: ①没有充分利用机器学习算法强大的特征提取能力, 提取每个颗粒位置与轮廓对级配识别是不必要的, 反而会限制算法本身的潜力; ②没有考虑“级配图像不确定性”, 即土料二维表面的级配与三维堆料的级配并不相同。

为在基于图像的粗粒土级配快速检测问题上取得技术突破, 本文首先研制了专门的土料级配图像收集装置, 收集了共计 877 种级配、22380 张图像的粗粒土级配图像数据集, 从而为模型的构建提供了坚实的数据基础。针对“级配图像不确定性”, 提出了任意数量图像输入的搜索-分析网络 (searcher-analyzer network, SaNet)。本文构建的级配识别模型, 无需繁琐的数字图像前处理过程, 能以较高精度直接识别级配, 对填方工程中的土料质量控制具有重要意义。

1 粗粒土级配土料图像数据库的收集与建立

1.1 土料类型与图像拍摄装置

为构建多样性的粗粒土级配图像数据集, 进而为深度学习模型的训练奠定数据基础, 本文采用了两种具有明显差异的土料进行试验, 一种是粒径介于 0.3~6 mm 的黄河粉土, 另外一种为 0.075~20 mm 的石英砂, 这两种土料在以往填方工程中得到了广泛应用, 具有一定的代表性。其中黄河粉土在混合过程中易起尘, 拍摄所得图像比较模糊 (图 1 (a)); 石英砂颗粒棱角分明, 图像较为清晰 (图 1 (b))。

为更高效地实现数据收集, 本文创新性地研制了一种粗粒土级配图像拍摄装置, 该装置集土料容纳、混合、拍摄为一体, 并通过连接电脑实现图像即时保存。



(a) 黄河粉土



(b) 石英砂

图 1 拍摄粗粒土表面所获得的级配图像

Fig.1 Gradation photos of coarse-grained soil surfaces

装置结构如图 2 所示。顶部为加料口 (图 2 (a)), 不同粒径的土料由此加入以配置不同的级配; 装置正中心处为一空心桶, 上部开口, 下附挡板 (图 2 (b)), 通过转动装置外的手柄 (图 2 (a)) 可控制该桶和挡板一同旋转, 从而实现土料快速搅拌混合; 装置右侧部分设置一个悬挑扁平钢板 (图 2 (c)), 钢板上绑有小型相机, 镜头朝下, 与相机相连的导线伸出并连接电脑以实现拍摄控制和图像保存 (图 2 (d)); 当外置手柄被转动时, 挡板带动土料向上运动, 同时空心桶开口由上向下变动以防止拍摄装置被土料击中。当挡板达到最高点时, 土料全部落下, 空心桶的开口朝下使得镜头曝光, 此时进行拍摄。



(a) 左侧外观



(b) 左侧内部结构



(c) 右侧内部结构



(d) 右侧外观

图 2 一种粗粒土级配图像拍摄装置

Fig. 2 Photo-taking devices for gradation of coarse-grained soil

1.2 图像收集流程

将黄河粉土的颗粒划分为 6 个粒组, 粒组的粒径范围分别是 0.3~0.6, 0.6~1.18, 1.18~2.36, 2.36~3.15, 3.15~4.15, 4.15~6 mm。石英砂同理, 粒径范围分别是 0.075~0.25, 0.25~0.5, 0.5~1, 1~5, 5~10, 10~20 mm。

为提高数据收集效率, 首先将黄河粉土、石英砂进行筛分, 分别获得 6 个基础粒组的颗粒。然后按照设计级配, 计算每个粒组所需的颗粒质量, 人工配置给定级配的土料。以石英砂收集为例, 具体流程包含以下步骤:

(1) 配置初始级配。选用 500 g 的 10~20 mm 粒组的石英砂颗粒 (级配 A_0), 由加料口加入拍摄装置。

(2) 缓慢转动手柄, 旋转滚筒, 使颗粒混合均匀, 通过连接拍摄仪的电脑操纵拍摄, 将所得图像保存。重复该过程 30 次, 每种级配的土料拍摄 30 张图像 (其中黄河粉土为混合 20 次, 并针对每种级配的土料拍摄了 20 张图像)。

(3) 在级配 A_0 的土料基础上, 向该土料中添加新的颗粒 (例如 50 g 的 5~10 mm 粒组的颗粒), 获得新的土料, 其级配为 A_1 。

(4) 重复过程 (2), (3), 直至 50 g 的土料无法引起级配显著变化, 得到级配 A_0, A_1, \dots, A_N 。

(5) 回收装置中的土料, 将装置清理干净以防止影响下一级配的图像采集。

(6) 配置下一个初始级配, 重复过程 (1)~(5), 直至完成所有级配的采集。

按照上述流程, 最终收集到的具体级配曲线见图 3。采用筛分的黄河粉土颗粒人工配置了 393 种不同级配的土料, 其土体分类包括角砾、砾砂、粗砂, 共 3 类 (图 3 (a))。类似地, 采用石英砂颗粒配置了 484 种不同级配的土料, 其土体分类包括角砾、砾砂、粗砂、中砂、细砂, 共 5 类 (图 3 (b))。

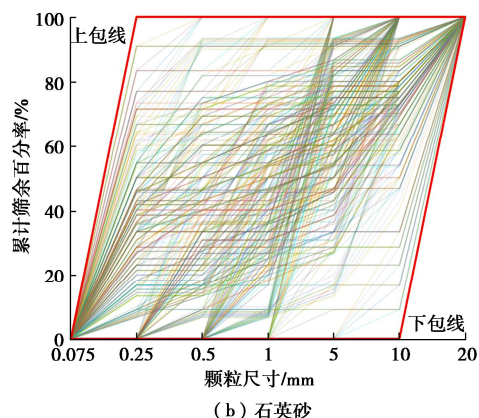
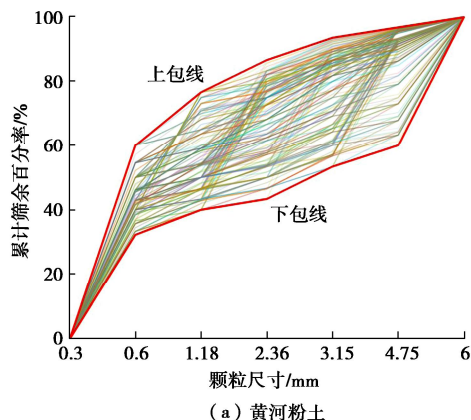


图 3 数据库中黄河粉土、石英砂的全部级配

Fig. 3 All gradations of yellow river silt and quartz sand in database

1.3 数据集划分与图像预处理

在完成数据收集后, 按照 0.80:0.15:0.05 的比例随机划分为训练集、验证集与测试集。黄河粉土共 393 个级配, 划分后训练集、验证集、测试集分别包含 314, 60, 19 个级配; 石英砂共 484 个级配, 划分后训练集、验证集、测试集分别包含 387, 73, 24 个级配。

如图 4 所示, 在相机拍摄所得原始图像中, 装置占有较大比例, 这部分对级配预测没有贡献, 反而会使计算资源消耗急剧增加, 因此从图像中部截取 1000×1000 的子图用于后续的机器学习模型的输入。



图 4 裁剪子图以去除无用信息

Fig. 4 Cropping subgraph to remove unwanted information

由于与级配相关的土颗粒边缘特征与颜色信息相关性较低, 可以将图像转化为灰度图以减少输入维度, 提高识别效率。此外, 为了防止模型过拟合, 采用“数据增强”技术: 将图像进行概率为 50% 的水平、竖向翻转, 这相当于使数据增大到原来的 4 倍。最后, 将图像由 1000×1000 缩放为 224×224 , 这是现有成熟 CNN 模型中普遍采用的尺寸, 与网络架构具有较好的匹配性。上述流程如图 5 所示, 需要指出的是, 数据增强只对训练集进行, 因为只有这部分作用于模型参数更新。

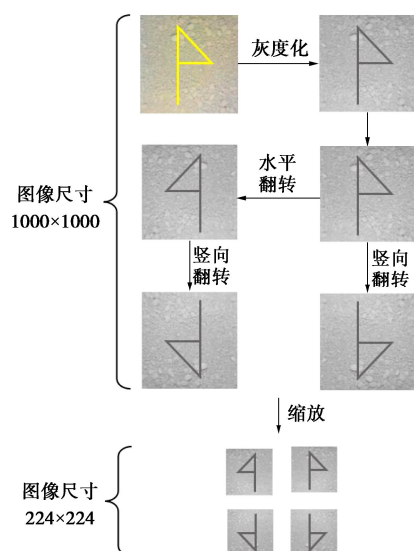


图5 图像预处理过程

Fig. 5 Image preprocessing

1.4 模型训练标签生成

在机器学习问题中, 标签即模型预测的目标。级配预测的难点在于其自身的数学特征, 具体而言: ①级配曲线是增函数, 且由 0 增加到 1; ②每一点的值代表累计筛余百分率, 因此数值总小于 1。这两个特征使得直接预测级配曲线存在巨大困难, 因为一般神经网络的输出遍布整个实数轴。

在数据收集过程, 记录的是与图像对应的级配 G , 受到“softmax”函数的启发 (2.2 节式 (4)), 模型预测的标签 O 按照式 (1) 计算, 事实上, 该变量即级配分布曲线。

$$O_i = G_i - G_{i-1} \quad (1)$$

式中: $1 \leq i \leq 6$ 且为整数; G_0 恒等于 0 (即粒径小于 0 的累计筛余百分率)。

1.5 数据分享

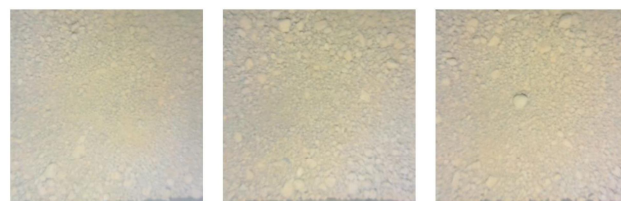
本文建立的“BJTU Gradation Photos”数据库将通过以下链接提供给公众: <https://github.com/Yuanen-Pang/BJTU-gradation-photos>。关于数据库的详细信息可以在这个网站上找到。笔者鼓励研究人员使用该数据库, 并希望该数据库的共享能将粗粒土级配识别模型的研究推向新的高度。

2 考虑级配图像不确定性的级配识别模型

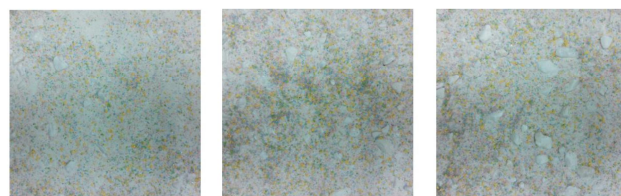
2.1 级配图像不确定性

如图 6 (a), (b) 所示, 同一级配下的三幅图像由左到右堆料表面大颗粒含量逐渐增加, 即相同的级配会拍摄到较大差异的表面图像, 本文称之为“级配图像不确定性”。图像是二维的, 理论上讲图像的标签应当是“表面级配”而不是整个堆料的级配, 否则会

导致 CNN 模型出现困惑。针对该问题, 在下一节调整深度学习网络的架构, 使其具有考虑“级配图像不确定性”的能力。



(a) 某同一级配黄河粉土样本的3张表面图像



(b) 某同一级配石英砂样本的3张表面图像

图6 “级配图像不确定性”展示

Fig. 6 Presentation of "Uncertainty of gradation image"

2.2 SaNet 网络架构与模型构建

受到注意力机制的启发^[15-16], 引入搜索分析网络 (searcher-analyzer network, SaNet) 来解决“级配图像不确定性”问题, 其结构如图 7 所示。SaNet 中有 3 个子网络: “搜索者” (Searcher) 网络用于级配相关特征提取, “分析者 (后部分)” (Analyzer_r) 网络用于单张图像级配结果预测, “分析者 (前部分)” (Analyzer_f) 负责计算不同图像的权重。通过为不同图像的级配预测结果赋予权重, 得到最终级配预测结果。

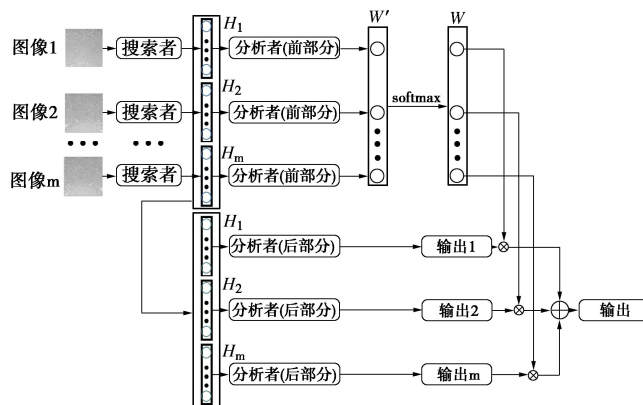


图7 搜索-分析网络结构

Fig. 7 Architecture of SaNet

SaNet 的计算过程如下:

(1) 将同一级配下拍摄到的 m 张土料表面图像 (已完成预处理) $X_1 \sim X_m$ 输入 Searcher 网络, 得到由每一张图像提取的级配相关特征 $H_1 \sim H_m$, 如式 (2)。

$$H_i = \text{Searcher}(X_i) \quad (2)$$

(2) 将 $X_1 \sim X_m$ 输入 Analyzer_f 网络, 得到未归一化权重 W' , 接着进行“softmax”操作得到归一化的权重 W , 如式 (3), (4)。

$$W'_i = \text{Analyzer}_i(H_i) \quad , \quad (3)$$

$$W_i = \frac{\exp(W'_i)}{\sum_{j=1}^m \exp(W'_j)} \quad . \quad (4)$$

式中: W'_i 为 W' 向量的第 i 个元素; W_i 为 W 向量的第 i 个元素。

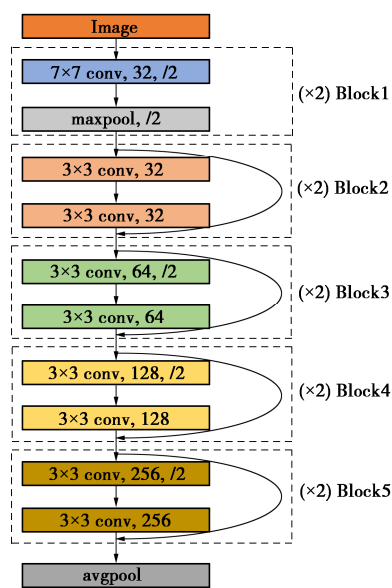
(3) 将 $X_1 \sim X_m$ 输入 Analyzer_i 网络, 得到每张图像的预测级配 $Y'_1 \sim Y'_m$ (由于每个 Y'_i 都表示向量, 因此 i 标在外侧), 如式 (5)。

$$Y'_i = \text{Analyzer}_i(H_i) \quad . \quad (5)$$

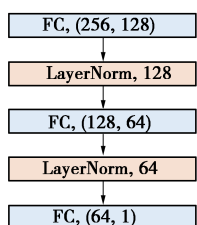
(4) 将 W 各元素与各个图像的 Y' 相乘再相加, 得到最终级配预测结果, 如式 (6)。

$$Y = \sum_{i=1}^m W_i Y'_i \quad . \quad (6)$$

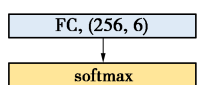
Searcher 网络可以是现有任何成熟的 CNN 主体结构, Analyzer_i 、 Analyzer_r 则是任意的多层感知机^[17-18]。本文采用的具体结构如图 8 所示, 搜索者采用 ResNet^[19], “($\times n$)” 代表结构重复 n 次。



(a) 搜索者网络



(b) 分析者(前部分)网络



(c) 分析者(后部分)网络

图 8 SaNet 各部分网络架构

Fig.8 Network architecture of each part of SaNet

2.3 SaNet 模型训练方法

SaNet 模型的训练分为两个阶段: 第一个阶段单独训练 ResNet 网络, 由单张图像识别级配, 然后将其拆成 SaNet 的两个成分, Searcher 网络和 Analyzer_r 网络; 在第二个阶段, 增加名为 Analyzer_i 的新网络, 与前面两个网络合成 SaNet 模型, 此阶段只对 Analyzer_i 中的参数进行更新。

为了保证 SaNet 的权重分配功能在各种输入数量下都能很好的发挥作用, 引入两次随机操作实现输入图像数量与成分的不确定性。以图 9 所示黄河粉土取样为例进行说明, 包含以下步骤:

(1) 根据设置的批量大小超参数 B 从训练集中随机取出 B 个级配及该级配下拍摄到的所有土料图像;

(2) 产生介于 1~20 (上限等于单个级配拍摄的图像总数, 石英砂为 1~30) 的随机整数 m 。

(3) 根据步骤 (1) 的级配选择结果, 从每个级配中随机抽取 m 张图像作为一个批量中的单个样本, 将一个批量输入 SaNet 模型进行计算。

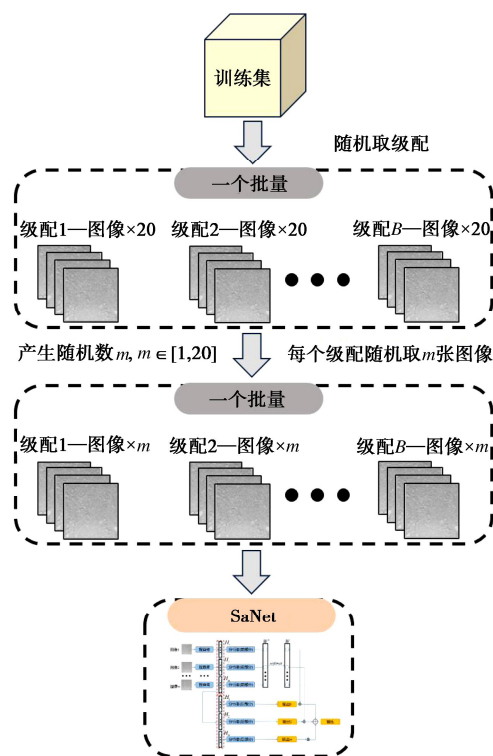


图 9 SaNet 网络训练方法

Fig. 9 Training method of SaNet

2.4 模型评价指标

采用平均绝对值误差 (mean absolute error, MAE)、决定系数 (coefficient of determination, R^2) 在测试集的平均值 $\overline{\text{MAE}}$ (下面简称平均误差) 与 $\overline{R^2}$ 进行模型评价, 如式 (7) ~ (10) 所示。MAE 为非负数, 越

接近0代表级配识别精度越高。 R^2 取值为0~1, 越接近1精度越高。

$$MAE = \frac{\sum_{i=1}^6 |O'_i - O_i|}{6}, \quad (7)$$

$$\overline{MAE} = \frac{\sum_{i=1}^n MAE}{n}. \quad (8)$$

式中: O'_i 为级配分布曲线预测值的第 i 个元素; O_i 为真实值的第 i 个元素; n 为测试集样本数量。

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{G}_i - G_i)^2}{\sum_{i=1}^n (G_i - \bar{G})^2}, \quad (9)$$

$$\overline{R^2} = \frac{\sum_{i=1}^n R^2}{n}. \quad (10)$$

式中: \hat{G} 为级配曲线预测值; G 为真实值; \bar{G} 为 G 中元素的平均值。

3 基于 SaNet 架构的级配识别模型应用效果

3.1 SaNet 和 ResNet 级配识别精度对比

ResNet18、ResNet34 与 SaNet (输入所有图像) 在黄河粉土、石英砂测试集上的应用效果如图 10。对于黄河粉土: 三者的 \overline{MAE} ($\times 10^{-2}$) 分别为 2.16, 2.07, 1.63, $\overline{R^2}$ 分别为 0.990, 0.991, 0.995。对于石英砂: \overline{MAE} ($\times 10^{-2}$) 分别为 1.85, 2.36, 1.21, $\overline{R^2}$ 分别为 0.975, 0.956, 0.992。ResNet34 的层数几乎是 ResNet18 的两倍, 但级配识别精度在黄河粉土上略有提升, 石英砂不升反降; 相比之下, 基于 ResNet18 构建的 SaNet 使得两种土样的级配识别精度都大幅提高。这说明制约模型精度进一步提升的因素并非网络复杂度不够, 而是“级配图像不确定性”导致的“输入—输出”关系不合理, SaNet 网络能够有效解决这一问题。

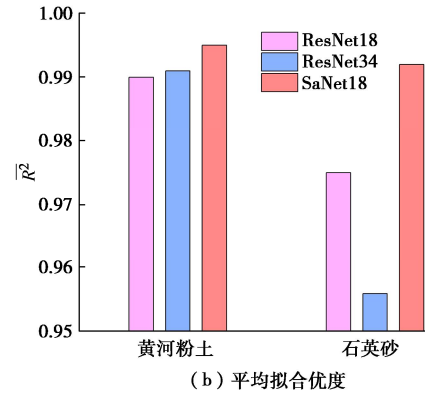
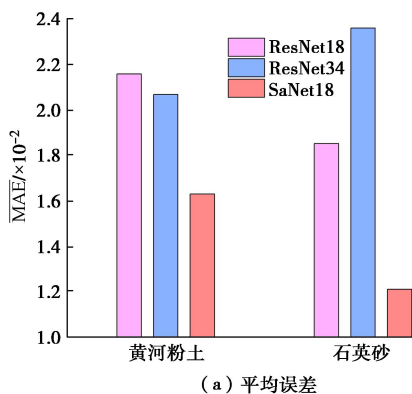


图 10 不同级配识别模型应用效果对比

Fig. 10 Comparison of application effects of different gradation recognition models

3.2 SaNet 和 P-ResNet 级配识别精度对比

除了采用 SaNet 来降低土体表面图像级配信息的不确定性外, 还可以通过对多张图像级配识别结果取平均来降低其不确定性, 即将多张图像的 ResNet 级配识别结果取平均, 作为最终的级配识别结果, 称之为 ResNet 级配均值, 记为 P-ResNet。为进一步了解 SaNet 对精度的提升效果, 将其与 P-ResNet 进行对比, 结果如图 11 所示。

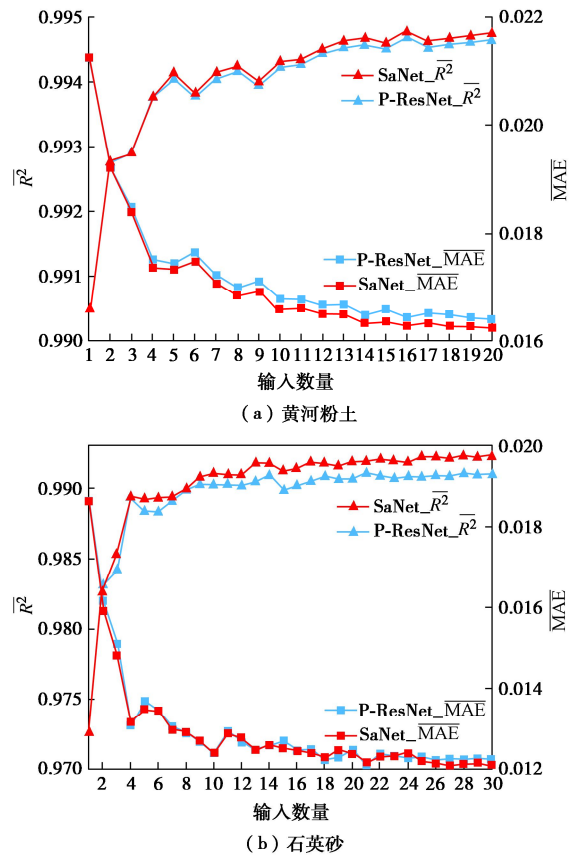


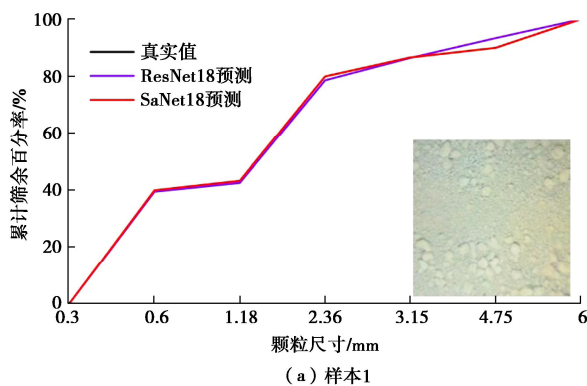
图 11 不同输入数量下 SaNet 与 P-Resnet 识别精度对比

Fig. 11 Comparison of recognition accuracy between SaNet and P-ResNet with different numbers of inputs

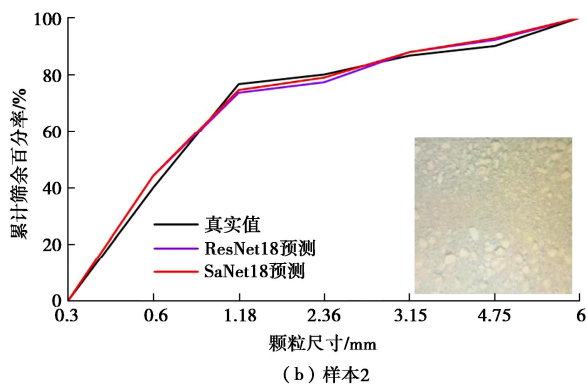
随着输入图像数量的增加,二者精度都逐渐提高;在输入数量为2的情况下,SaNet18与P-ResNet18精度差异不大;输入数量增加到3及以后,SaNet18在黄河粉土上的MAE和 R^2 明显优于P-ResNet18;在石英砂上的MAE差别相对较小,但比较 R^2 可以发现SaNet18依然优越,说明SaNet18的级配识别效果优于简单地取ResNet结果均值,这是由于SaNet为不同结果赋予的权重是根据输入计算得到的,而ResNet只是简单等权。

3.3 SaNet 模型应用效果展示

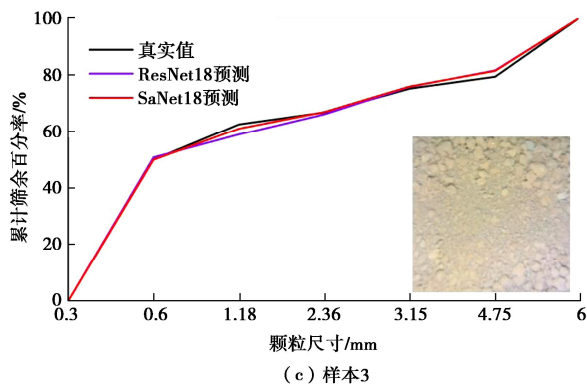
从黄河粉土、石英砂测试集中各自随机抽取3个样本,比较ResNet18和SaNet18的级配识别效果,土料图像及识别结果如图12,13所示。图12中黄河粉土的级配较容易识别,两个模型都能很好的工作,但SaNet18精度略高。



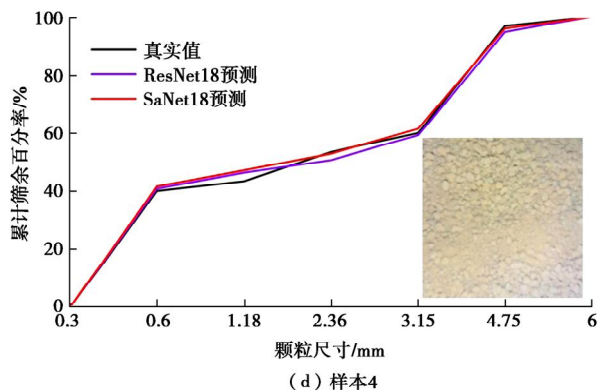
(a) 样本1



(b) 样本2



(c) 样本3

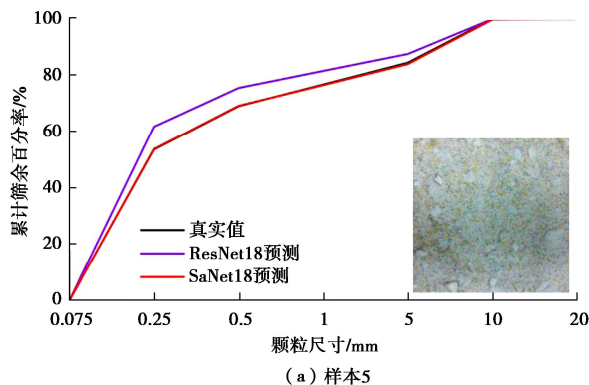


(d) 样本4

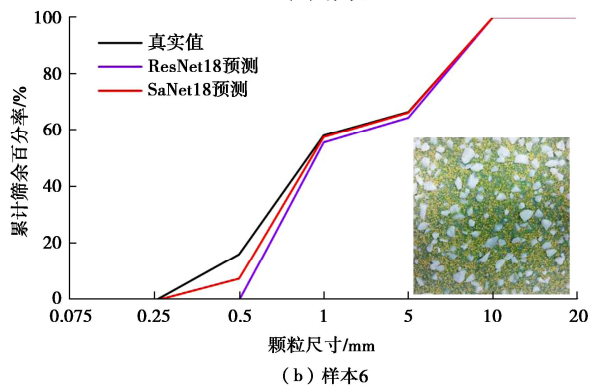
图12 黄河粉土随机样本级配累计曲线预测

Fig. 12 Predicted results of gradation curves of random Yellow River silt samples

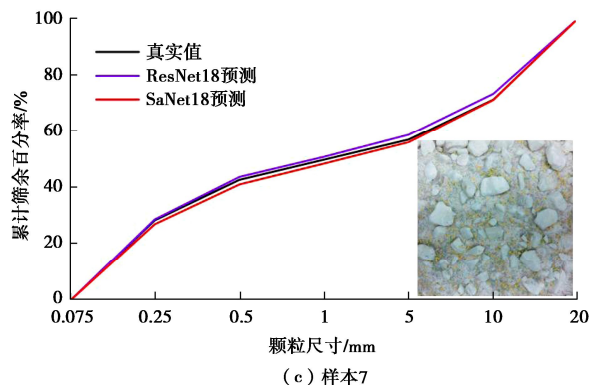
图13中石英砂上ResNet18预测结果与真实级配有明显偏离,因为粒径范围更大,“级配图像不确定性”更加明显。相比之下,SaNet预测的级配曲线与真实值仍能很好的匹配。这表明SaNet模型对“级配图像不确定性”问题具有较强的处理能力,识别效果能够满足工程需求。



(a) 样本5



(b) 样本6



(c) 样本7

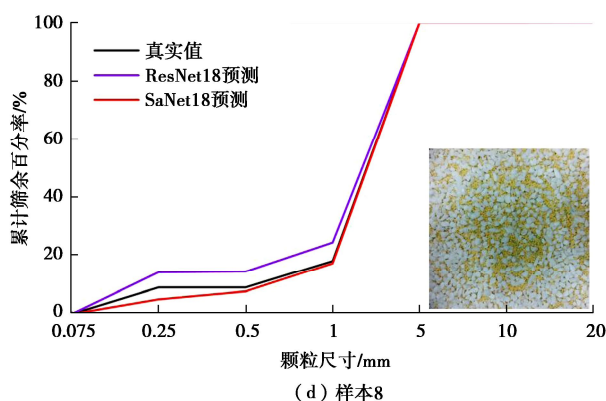


图13 石英砂随机样本级配曲线预测 (SaNet)

Fig. 13 Predicted results of gradation curves of random quartz sand samples

4 级配识别可解释性的讨论

为探究 CNN 模型识别级配的机理, 将图 12 中样本 3 输入 ResNet18, 从图 8 (a) 中 Block1~Block5 输出的特征图中各自选择 3 张进行可视化, 结果如图 14 所示。该样本的特点是: “较大粒径”的颗粒主要分布在图像上部、左下部及右下部, 而“较小粒径”的颗粒主要分布在图像中部 (图 14 (a))。需要说明的是, 特征图中某一区域越亮, 意味着该部分受到模型的关注越多, 对于级配预测的贡献越大。为方便讨论, 后文在对应 Block 后加“-x”代指图 14 (b) 中不同列的特征图, 比如“Block1-1”表示 Block1 中第一列的特征图。

由图 14 (b) 可知, CNN 识别级配是特征图功能分化的过程。具体而言: 在 Block1 的每张特征图中, 明亮区域遍布整张图像, 这意味着单个特征图对于所有粒径的颗粒都进行关注; 在 Block3 中, 特征图出现明显的“空洞”, 这表示特征图出现功能分化, 单个特征图不再关注全部颗粒。比如, 将特征图与 14 (a) 中原图进行位置对应, 发现 Block3-1 关注“较小粒径”区域, Block3-2 关注“较大粒径”区域; 在 Block5 中, 单个特征图关注的区域进一步缩小, 如 Block5-1 关注的只是“较小粒径”区域的一个子集, 即“较小粒径”这一笼统的范围被进一步分割。

此外值得注意的是, 同一个 Block 中的不同特征图呈现出功能互补的现象。具体而言, 从 Block2 开始, 第一列和第二列的特征图中明亮区域的重合度有明显降低。Block4-1 和 Block4-2 尤其明显, 两者几乎互为对方的补集。这意味着 CNN 将不同粒径的颗粒分配到不同的特征图中给予关注, 而所有特征图所关注范围的并集仍能覆盖全部颗粒。

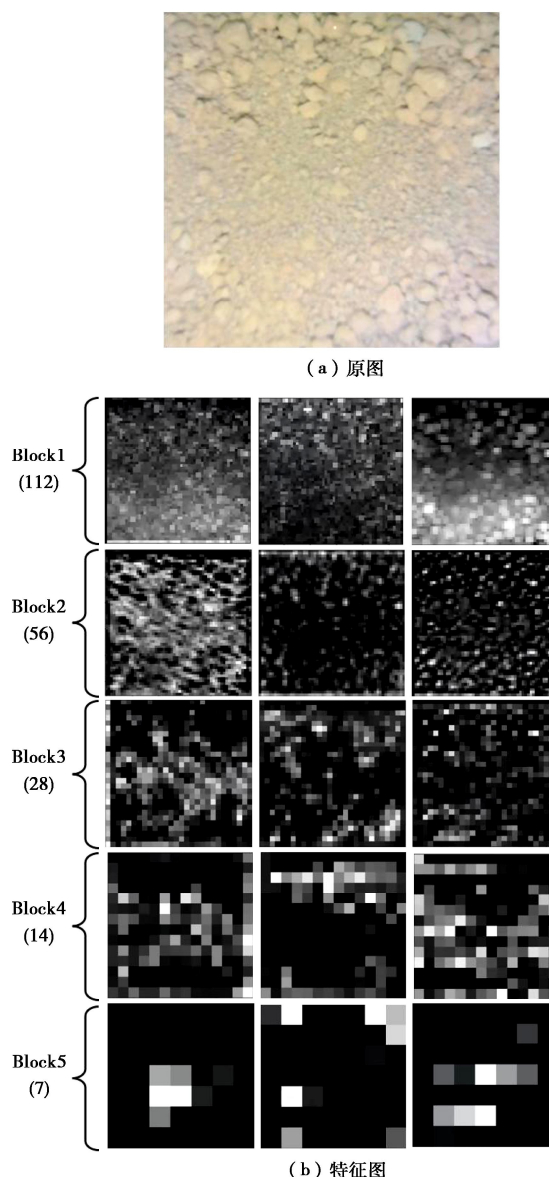


图14 随机选出某黄河粉土样本的特征图可视化 (括号内为特征图边长)

Fig. 14 Visualization of feature maps from a randomly selected Yellow River silt sample (bracketed numbers indicate side lengths of feature maps)

与轮廓识别法将颗粒一个个提取不同, CNN 的做法是同时提取类似粒径的颗粒。比如在 Block3-1、Block3-2 中, 明亮区域呈现出明显的连通性, 只是模型对不同位置的关注程度不同。在轮廓识别法中, 图像模糊、颗粒黏连会直接导致算法失效, 尤其是第二个原因造成该方法难以用于粒径小于 5 mm 的颗粒划分。相比之下, CNN 并不关注个别颗粒的轮廓, 而是逐层堆叠卷积操作对类似粒径的颗粒进行同时提取, 这可能是 CNN 在粗粒土上能够奏效的一个重要原因。需要强调的是, CNN 目前在可解释性方面的进展仍十分不足, 本文暂时无法对级配识别的详细机理给予解释。

石英砂的特征图可视化结果与黄河粉土具有相似的规律,限于篇幅原因,此处不再展开。需要指出的是:理论上低于 1 个像素的颗粒是无法识别的,因此能够识别的颗粒粒径和图像的分辨率有关。在输入图像尺寸为 224×224 的条件下,模型能够识别的粒径理论极限是 0.246 mm,恰好能区分 0.075~0.25 mm 与 0.25~0.5 mm 这两个粒组。因此,由于受到图像像素的限制,本文方法不宜应用于细粒土。

5 结 论

针对填方工程中的土料级配快速实时识别需求,构建了包含两种颗粒类型、超过 800 种级配且总图像数超过 2 万张的粗粒土图像数据库。为解决二维图像与三维级配不匹配——即“级配图像不确定性”问题,构建了搜索-分析网络(SaNet),主要得到以下 3 点结论。

(1) 基于大量的土料表面图像,采用卷积神经网络进行粗粒土级配的识别是可行的,SaNet 模型级配识别的平均误差在黄河粉土、石英砂分别为 1.63%, 1.21%, 决定系数分别为 0.995, 0.992。

(2) 在“级配图像不确定性”显著的情况下,基于 ResNet18 构建的 SaNet 识别精度明显优于 ResNet34,简单增加网络深度反而会使得识别精度下降,采用 SaNet 进行级配识别是必要的。

(3) 提出的 SaNet 网络能够有效解决“级配图像不确定性”,模型精度随相同级配土料下输入图像数量的增加稳定提升,降低的最大误差可达 20%以上。

参考文献:

- [1] 何忠明, 杨煜, 段旭龙. 粗粒土路堤填料路用性能及其循环动应力试验[J]. 长安大学学报(自然科学版), 2019, 39(2): 27-34. (HE Zhongming, YANG Yu, DUAN Xulong. Experimental on road performance and cyclic dynamic stress of coarse-grained soil subgrade[J]. Journal of Chang'an University (Natural Science Edition), 2019, 39(2): 27-34. (in Chinese))
- [2] 王天亮, 张飞, 宋宏芳, 等. 高速铁路路基粗粒土填料动静力特性试验研究[J]. 铁道学报, 2022, 44(4): 127-135. (WANG Tianliang, ZHANG Fei, SONG Hongfang, et al. Experimental study on dynamic and static mechanical properties of coarse-grained soil filled in high-speed railway subgrade[J]. Journal of the China Railway Society, 2022, 44(4): 127-135. (in Chinese))
- [3] ZHANG C Y. Research on the frost-heave performances of filling material consisted of coarse grained soil for high-speed railway subgrade[J]. Journal of Railway Engineering Society, 2018, 35(2): 24-28.
- [4] NIE R S, SUN B L, CHENG L H, et al. Resilient characteristics test of coarse-grained soil filler for heavy haul railway subgrade[J]. Journal of the China Railway Society, 2022, 44(1): 96-104.
- [5] 陈生水. 高土石坝变形破坏过程预测理论和防控技术创新[J]. 岩土工程学报, 2022, 44(7): 1211-1219. (CHEN Shengshui. Innovations in prediction theories and prevention technologies for deformation-induced failure process of high earth and rockfill dams[J]. Chinese Journal of Geotechnical Engineering, 2022, 44(7): 1211-1219. (in Chinese))
- [6] 李希, 张升, 盛岱超, 等. 基于抽样可靠性的颗分试验取样数量研究[J]. 岩土工程学报, 2016, 38(11): 2122-2127. (LI Xi, ZHANG Sheng, SHENG Daichao, et al. Reasonable sample capacity for grain-size analysis tests based on sampling reliability[J]. Chinese Journal of Geotechnical Engineering, 2016, 38(11): 2122-2127. (in Chinese))
- [7] 吕超, 唐朝生, 李胜杰, 等. 基于数字图像处理技术的砂土颗粒级配分析研究[J]. 高校地质学报, 2019, 25(3): 431-436. (LÜ Chao, TANG Chaosheng, LI Shengjie, et al. Gradation analysis of sand particles based on digital image processing technology[J]. Geological Journal of China Universities, 2019, 25(3): 431-436. (in Chinese))
- [8] 于沭, 温彦锋, 王玉杰, 等. 基于图像识别技术的土石料级配检测系统[J]. 中国水利水电科学研究院学报, 2019, 17(6): 439-445. (YU Shu, WEN Yanfeng, WANG Yujie, et al. Gradation testing system of rockfill material based on image recognition technology[J]. Journal of China Institute of Water Resources and Hydropower Research, 2019, 17(6): 439-445. (in Chinese))
- [9] 程永春, 马健生, 颜廷野, 等. 基于数字图像处理技术的沥青混合料级配检测方法[J]. 科学技术与工程, 2017, 17(32): 332-338. (CHENG Yongchun, MA Jiansheng, YAN Tingye, et al. Asphalt mixture gradation detection method based on digital image processing technology[J]. Science Technology and Engineering, 2017, 17(32): 332-338. (in Chinese))
- [10] 雷雨萌, 陈祖煜, 于沭, 等. 基于深度阈值卷积模型的土石料级配智能检测方法研究[J]. 水利学报, 2021, 52(3): 369-380. (LEI Yumeng, CHEN Zuyi, YU Shu, et al. Intelligent detection of gradation for earth-rockfill materials base on deep otsu convolutional neural network[J]. Journal of

- Hydraulic Engineering, 2021, **52**(3): 369-380. (in Chinese))
- [11] FAN H Y, TIAN Z H, XU X B, et al. Rockfill material segmentation and gradation calculation based on deep learning[J]. Case Studies in Construction Materials, 2022, **17**: e01216.
- [12] 刘禹杉, 孙淼军, 吴帅峰, 等. 土石料粒径与级配的图像智能识别研究[J]. 岩土工程学报, 2023, **45**(增刊 1): 59-62. (LIU Yushan, SUN Miaojun, WU Shuaifeng, et al. Intelligent image recognition of particle size and gradation of earth-rock[J]. Chinese Journal of Geotechnical Engineering, 2023, **45**(S1): 59-62. (in Chinese))
- [13] ZHOU X, GONG Q, LIU Y, et al. Automatic segmentation of TBM muck images via a deep-learning approach to estimate the size and shape of rock chips[J]. Automation in Construction, 2021, **126**: 103685.
- [14] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2017, **39**(4): 640-651.
- [15] LIU Z, LI L, FANG X, et al. Hard-rock tunnel lithology prediction with TBM construction big data using a global-attention-mechanism-based LSTM network[J]. Automation in Construction, 2021, **125**: 103647.
- [16] YANG D, GU C, ZHU Y, et al. A concrete dam deformation prediction method based on LSTM with attention mechanism[J]. Ieee Access, 2020, **8**: 185177-185186.
- [17] EBRAHIMABADI A, AZIMIPOUR M, BAHREINI A. Prediction of roadheaders' performance using artificial neural network approaches (MLP and KOSFM)[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2015, **7**(5): 573-583.
- [18] KOOPIALIPOOR M, ASTERIS P G, MOHAMMED A S, et al. Introducing stacking machine learning approaches for the prediction of rock deformation[J]. Transportation Geotechnics, 2022, **34**: 100756.
- [19] HE K, ZHANG X, REN S, et al. 2016. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Las Vegas, 2016.

特殊岩土力学与工程问题研讨会 (1 号通知)

主办单位: 中国力学学会岩土力学专业委员会

承办单位: 桂林理工大学, 广西岩土力学与工程重点实验室

协办单位: 安徽建筑大学(待增补)

会议背景: “一带一路”沿线国家地域广阔, 地质条件复杂多样, 引发了不少世界性的特殊岩土工程难题。我国西南地区, 特别是广西、贵州、云南等地区, 岩、膨胀土、红黏土等特殊地质发育, 工程建设中面临很多的特殊岩土力学与工程问题。此外, 作为有色金属资源之乡的广西, 矿产开采伴生的岩土力学与工程问题也亟待解决。在此背景下, 本次研讨会主要面向复杂工程地质环境下特殊岩土的力学与工程问题进行交流和探讨, 为推动“一带一路”沿线基础设施建设贡献力量。本次研讨会主要围绕各类型特殊岩土的力学特性以及岩溶区

地质灾害的发生机理进行交流, 热忱邀请并欢迎国内外相关学者、工程师和同学参加本次研讨会!

会议主要议题 (包括但不限于): ①特殊岩土的力学特性、灾变机制及本构理论; ②能源开发和资源化利用中特殊岩土的力学特性; ③新型加固技术形成的特殊岩土的力学特性及工程应用; ④岩溶地区常见地质灾害的发生机理及防治措施。

会议时间、地点: 2024 年 10 月 11 日~10 月 13 日, 2024 年 10 月 11 日 (周五): 全天注册、报到, 2024 年 10 月 12 日 (周六): 大会学术报告与讨论 2024 年 10 月 13 日(周日): 学会党建活动 (长湘江战役纪念馆+灵渠)、地质考察 (漓江沿岸岩溶区岩土力学特性及工程地质灾害防治现场研讨), 地点: 广西桂林。

联系人: 于啸波 (15207733161)、吴起 (13093554231)。
(会议组委会 供稿)