

基于遗传算法与神经网络的逆向侵蚀 管涌通道表征方法

梁越^{1,2,3}, 饶育锋¹, 赵卓越⁴, 许彬^{1,2,3}, 杨晓霞¹,
夏日风¹, 邓惠丹¹, RASHID Hafiz Aqib¹

(1. 重庆交通大学 河海学院, 重庆 400074; 2. 重庆交通大学 国家内河航道整治工程技术研究中心, 重庆 400074;
3. 重庆交通大学 水利水运工程教育部重点实验室, 重庆 400074; 4. 中交第四航务工程勘察设计院有限公司, 广东 广州 510230)

摘要: 堤防是应用最广泛且有效的防洪工程措施之一。然而, 由于堤防老化、加固措施不力以及复杂的地质条件, 在汛期常发生管涌等险情, 导致重大且往往难以修复的损失。以双层堤基逆向侵蚀管涌 (backward erosion piping, 简称 BEP) 为研究对象, 开展遗传算法 (genetic algorithm, 简称 GA) 优化的反向传播 (back propagation, 简称 BP) 神经网络对逆向侵蚀管涌通道进行刻画研究。主要工作及成果包括: (1) 通过非均质含水层中 BEP 的数值模拟构建训练数据集, 并利用室内沙槽管涌试验验证了该数据集的可靠性; (2) 从 BEP 室内试验的 II、III 和 IV 组数据中提取水头 H 和渗透系数 K 数据, 进行数据集扩充, 并优化 GA-BP 模型以表征 I 组试验结果, 结果表明优化后的模型能更准确地刻画 $K \leq 1.0$ cm/s 的区域; (3) 利用优化后的 GA-BP 模型表征 BEP 通道的发展过程。结果表明, 该模型能准确捕捉总体发展趋势, 但在表征通道位置和尺寸方面与实际条件仍存在微小偏差。综上所述, 研究为表征 BEP 提供了有效工具, 并证明了 GA-BP 网络模型在该领域的实际应用潜力。

关键词: 逆向侵蚀管涌; 管涌通道; BP 神经网络; 遗传算法; 渗透系数

中图分类号: TV 411

文献标识码: A

文章编号: 1000-7598 (2026) 01-0323-14

Genetic algorithm-optimized back propagation neural network for the characterization of backward erosion piping channels

LIANG Yue^{1,2,3}, RAO Yu-feng¹, ZHAO Zhuo-yue⁴, XU Bin^{1,2,3}, YANG Xiao-xia¹,
XIA Ri-feng¹, DENG Hui-dan¹, RASHID Hafiz Aqib¹

(1. The College of River and Ocean Engineering, Chongqing Jiaotong University, Chongqing 400074, China;

2. National Engineering Research Center for Inland Waterway Regulation, Chongqing Jiaotong University, Chongqing 400074, China;

3. Key Laboratory of Hydraulic and Waterway Engineering of Ministry of Education, Chongqing Jiaotong University, Chongqing 400074, China;

4. CCCC - FHDI Engineering Co., Ltd., Guangzhou Guangdong 510230, China)

Abstract: The use of levees is one of the most prevalent and effective strategies for flood protection. However, owing to the ageing of levees, inconsistent reinforcement efforts, and complex geological conditions, hazards such as piping frequently arise during flood seasons, which lead to significant and often irreparable damage. This study investigates backward erosion piping (BEP) in the foundations of double-structured levees via a back-propagation (BP) neural network optimized by a genetic algorithm (GA). The primary contributions of this study include: 1) the construction of a training dataset through numerical simulations of BEP in heterogeneous aquifers and validation of the dataset against laboratory sandbox piping tests to verify its reliability; 2) the extraction of head H and permeability coefficient K data from Groups II, III, and IV in the BEP laboratory tests, augmentation of the dataset, and optimization of the GA-BP model to characterize test results in Group I, where the results demonstrate that the optimized model more

收稿日期: 2025-01-08

录用日期: 2025-07-31

基金项目: 国家自然科学基金 (No.52379097, No.52509138); 广西科技计划 (No.桂科 AA23062023); 重庆交通大学研究生科研创新基金 (No.2025S0028); 重庆市水利科技项目 (No.CQSLK-2024005); 重庆市教委科学技术研究计划 (No.KJQN202300744) 资助。

This work was supported by the Natural Science Foundation of China (52379097, 52509138), the Guangxi Science and Technology Program (GuiKe AA23062023), the Graduate Scientific Research and Innovation Foundation of Chongqing Jiaotong University (2025S0028), the Chongqing Water Conservancy Technology Project (CQSLK-2024005) and the Science and Technology Research Program of Chongqing Municipal Education Commission (KJQN202300744).

第一作者简介: 梁越, 男, 1985 年生, 博士, 教授, 主要从事水工灾害机制与防治方面的教学与科研工作。E-mail: liangyue2560@163.com

通信作者: 饶育锋, 男, 2001 年生, 硕士研究生, 主要从事水工灾害机制与防治方面的研究。E-mail: ryfeng263643@163.com

accurately characterizes areas where the $K \leq 1.0$ cm/s; and 3) the use of the optimized GA-BP model to characterizes the development of a BEP channel. The results indicate that the model accurately captures the general trends. However, minor discrepancies remain in the characterized channel location and size compared with the actual conditions. In conclusion, this study offers an effective tool for characterizing BEP and demonstrates the potential of the GA-BP network model for practical applications in this field.

Keywords: backward erosion piping; piping channel; back propagation neural network; genetic algorithm; permeability coefficient

1 引言

堤防作为关键的水利工程设施,在防洪减灾中发挥着不可替代的作用,其结构稳定性直接关系到沿岸居民的生命财产安全与社会稳定^[1]。统计数据显示,截至 2023 年底,我国在沿海和内陆地区建设的堤防总长度已超过 40 万 km,有效保护了大量人口和经济实体^[2]。然而,在取得显著建设成就的同时,堤防安全仍面临诸多挑战,其中逆向侵蚀管涌(backward erosion piping, 简称 BEP)是对堤防结构完整性构成持续威胁的突出问题之一^[3]。逆向侵蚀管涌是指在水流作用下,堤基或坝基中的细颗粒材料被逐渐冲刷带离的现象^[4-6]。随着渗流持续作用,这些颗粒不断迁移,最终形成逆水流方向发展的管状通道。该过程若不受控制,将导致挡水结构失稳甚至破坏^[7]。因此, BEP 被公认为堤防最主要的安全风险之一,也是导致堤防溃决的关键因素。根据水利部统计,我国每年记录的管涌险情达数百起,且集中发生于主汛期^[8]。例如,2024 年 7 月湖南省华容县团洲湾堤防发生的 BEP 险情,导致约 2 亿 m³洪水下泄,紧急转移群众 7 680 人,对当地社会经济和民生造成严重冲击^[9]。BEP 发育过程具有高度随机性和隐蔽性,传统监测手段难以实现有效探测,这对现有预警体系构成了严峻挑战^[10]。因此,开发先进技术以提升 BEP 监测预警能力,已成为保障人民生命财产安全的迫切需求。

目前,地球物理勘探是探测 BEP 的常用技术手段。Loperte 等^[11]采用探地雷达技术,成功实现对巴西利卡塔地区某大型水坝地下砂岩堤基的精准定位;张建清等^[12]通过融合地磁法、高密度电阻率法与微震法,建立了堤防渗漏区的精细探测方法;赵汉金等^[13]创新性地结合并行电法与瞬变电磁法,实现了坝体渗漏通道定向与坝肩隐患识别;Ge 等^[14]综合运用电阻率层析成像、探地雷达和面波分析,沿坝轴线完成地层分类与渗漏区定位。在示踪技术方面,Qiu 等^[15]通过温度测井、天然示踪电测井与盐类人工示踪试验的联合应用,实现了坝体渗漏通道的精确定位;Hamlyn 等^[16]利用电阻率层析成像与激发极化法,为水坝基础设施维护提供了关键数据支撑;Lin 等^[17]借助电阻率层析成像技术,在识别土坝

异常渗流路径的同时完成了土壤压实度评估。

尽管上述地球物理方法在特定条件下能有效探测坝体及其基础中潜在的渗漏和管涌通道,但由于地质和水文条件存在显著的异质性,难以准确区分由自然异质性引起的底层变化与管涌风险相关的变化,导致探测结果存在相当大的不确定性和误判可能^[18]。此外,监测数据与管涌发展过程之间缺乏定量关系,阻碍了管涌通道的快速准确定位和实时预警的实现^[19-21]。因此,传统方法在精确识别、动态监测和模型泛化能力方面仍存在明显局限性。

近年来,人工智能技术特别是神经网络方法,为复杂非线性特征的识别提供了新思路。翟越等^[22]基于径向基函数构建支持向量机分类模型,实现了堤防管涌发生概率的量化评估;饶小康等^[23]系统对比了深度信念网络、反向传播(back propagation, 简称 BP)神经网络与支持向量机在管涌识别中的性能表现;Lu 等^[24]创新性地将 YOLO 模型与多权重神经网络结合,实现了管涌图像特征的自动提取与灾害分类;Band 等^[25]基于随机森林、支持向量机和贝叶斯广义线性模型,建立了流域尺度的管涌侵蚀预测模型。这些研究成果充分展示了神经网络在解决复杂非线性问题和辅助 BEP 风险识别方面的应用潜力。

本研究提出了一种遗传算法优化的 BP 神经网络模型^[26-28]。该模型利用遗传算法自动优化神经网络的结构和参数,有效克服传统 BP 神经网络易陷入局部最优的缺陷,显著提升模型收敛速度与预测精度。更重要的是,遗传算法-反向传播(genetic algorithm-back propagation, 简称 GA-BP)模型能够直接从复杂监测数据中学习非线性映射关系,避免繁琐的物理参数建模过程,使其特别适用于高度异质性的地质环境,从而显著提高管涌通道识别的准确性与泛化能力。与传统方法相比,GA-BP 模型展现出更优越的工程适用性,为堤防管涌险情的及时准确预警提供了新的技术支撑。

2 模型表征方法

2.1 GA-BP 神经网络原理

BP 神经网络是一种应用广泛的多层前馈神经网络,通过误差反向传播算法进行训练^[29-31]。GA-BP 神经网络融合遗传算法,通过选择、交叉和变异操

作对 BP 网络的初始权值与阈值进行优化, 从而有效避免陷入局部极小值的风险。该方法通过全局优化初始参数, 显著提升了 BP 神经网络的训练性能。具体流程如图 1 所示。




图 1 基于遗传算法 (GA) 的 BP 神经网络流程图

Fig.1 Flowchart of BP neural network based on GA

(1) BP 神经网络模块

首先, 根据任务需求确定 BP 神经网络输入层、隐含层及输出层的节点数量, 随机初始化权值与阈值以构建初始解空间; 随后, 采用遗传算法对这些参数进行优化, 以确定最佳网络配置; 接着, 设定网络性能指标作为训练终止条件; 在训练过程中, 执行前向传播计算预测结果, 并通过反向传播算法调整网络参数; 最后, 评估网络误差, 若达到预设精度要求则输出最终预测结果, 否则继续迭代训练直至满足停止条件。

(2) 遗传算法模块

对试验数据进行预处理, 使其满足遗传算法的优化要求。将 BP 网络的权值与阈值进行基因编码, 以网络误差作为适应度评估标准。基于适应度值执行精英选择策略, 通过遗传交叉操作产生新解, 并对部分个体实施变异操作以维持种群多样性。重新计算适应度并更新最优个体记录, 若满足终止条件 (达到最大迭代次数或适应度收敛), 则输出优化后的最优解, 否则继续执行遗传进化循环。

2.2 模型数据集的构建方法

本研究采用了一种针对非均质含水层中 BEP 的数值模拟方法。该方法将对流作用视为 BEP 过程中的主导机制, 因此通过对流-扩散方程进行简化, 忽略扩散项, 得到如下 BEP 模型:

$$\nabla \cdot (K \nabla h) = S_s \frac{\partial h}{\partial t} + Q \quad (1)$$

$$\frac{\partial C_m}{\partial t} + \nabla \cdot (u C_m) = I \quad (2)$$

式中: I 为源项; H 为水头; S_s 为储水率; u 为流体渗流速度矢量; C_m 为液相中可动颗粒的浓度; K 为水力传导系数。

源项 I 定义为

$$I = \begin{cases} \alpha C_r \frac{u_a - u_c}{u_c}, & u_a \geq u_c \\ \beta C_m \frac{u_a - u_c}{u_c}, & u_a < u_c \end{cases} \quad (3)$$

式中: α 和 β 均为控制固相可动颗粒浓度 C_r 与液相可动颗粒浓度 C_m 间转化速率的经验系数; u_a 为局部渗流速度; u_c 为临界流速阈值。

式 (3) 表明, 当局部流速超过 u_c 时, 固相中的颗粒浓度 C_r 开始转化为液相中的可动颗粒浓度 C_m ; 反之, 当流速低于临界阈值时, 液相中的可动颗粒会沉降并重新转化为固相。

该方法能动态模拟管涌过程, 并已在 Liang 等^[32]非均质含水层逆向侵蚀管涌数值模拟方法中得到验证。

2.3 模型构建与优化

为有效评估 GA-BP 网络模型对管涌通道的表征能力, 基于前述构建的数据集方法, 选取渗流场中的水头 H 和渗透系数 K 作为训练数据。为同时考虑侵蚀效应与空间位置影响, 额外引入坐标信息 (X, Y)。为量化水流方向, 构建了特征水头参数 (L_H)。该参数通过对每个 X 轴位置上方的水头值进行排序和离散化分类 (0~3), 将连续的等势线形态转化为离散的数字标签, 从而表征水头的空间变化趋势。因此, 模型输入数据包括 H, X, Y 和 L_H , 输出数据为 K 。将整体数据集按随机方式划分为训练集 (80%) 和测试集 (20%)。具体参数设置如下:

(1) 遗传算法部分

初始种群规模设为 50, 遗传代数 (迭代次数) 50, 变量取值范围为 $[-1, 1]$ 。采用浮点数编码方式, 编码精度为 1×10^{-6} 。选择策略选用轮盘赌法, 交叉概率设为 0.7, 变异概率为 0.05。以均方根误差 RMSE 作为适应度函数指导遗传算法优化。经多轮优化后, 选取最优个体, 通过基因编码反解获得 BP 神经网络优化的初始权重与阈值。

(2) BP 网络部分

使用 newff 函数构建包含输入层、隐藏层和输出层的 3 层 BP 神经网络结构。隐藏层神经元数量设定为 5 个, 该数值经多次试验验证, 能够在模型拟合能力与泛化性能之间取得良好平衡, 既可有效捕捉输入数据中的非线性特征, 又能避免网络结构

过于复杂导致的过拟合及训练效率降低问题。数据输入前,采用 `mapminmax` 函数进行归一化处理以消除量纲与异常值影响。隐藏层激活函数选用双曲正切 S 型函数 (`tansig`), 其输出范围限于 $[-1,1]$, 具有较强的非线性映射能力, 有助于提升网络对复杂关系的表征效果。输出层采用线性激活函数 (`purelin`), 以适应连续变量的回归预测需求。

网络训练过程基于 `trainlm` 函数实现, 该函数集成 Levenberg-Marquardt (L-M) 算法。学习率 α 经多次预试验优化确定为 0.001, 该设置既可维持训练稳定性, 又能保障收敛效率 (学习率过高易引发训练震荡或难以收敛, 过低则可能导致收敛缓慢或陷入局部极小)。批处理规模依据样本量自动配置, 损失函数采用均方误差。最大训练迭代次数设置为 1 000 次, 误差阈值 (预测值与实际值间最小容许误差) 设为 1×10^{-6} , 最小梯度 (目标函数下降方向) 设定为 1×10^{-7} 。L-M 算法中最大阻尼系数为 1×10^9 , 最大验证失败次数为 35 次 (即若损失函数连续 35 次迭代未下降, 训练自动终止)。训练过程将在满足任一停止条件时立即结束。

2.4 模型精度评估指标

本研究采用平均绝对误差 MAE 与平均偏差误差 MBE 作为评估指标, 用以量化真实值与表征值之间的差异; 使用均方根误差 RMSE 评估表征误差的大小; 决定系数 R 则反映真实值与表征值之间的线性相关程度。

3 BEP 室内试验

3.1 试验装置

为获取适用于验证 GA-BP 模型可靠性的数据

集, 本研究设计了室内砂箱试验装置 (图 2), 用于模拟管涌过程并观测其发展及管道通道的形成。该装置主要由试验砂箱、上游供水系统、下游集水系统以及水头监测系统组成。




图 2 室内砂箱试验装置实物图

Fig.2 Diagram of the indoor BEP test setup

如图 3 所示, 试验砂箱外形尺寸为 $60 \text{ cm} \times 40 \text{ cm} \times 30 \text{ cm} \times 1 \text{ cm}$ (长 $\times$ 宽 $\times$ 高 $\times$ 壁厚), 采用透明亚克力板制作, 便于直观观测颗粒运移及管道形成过程。砂箱结构包含顶盖板与试验箱体, 箱体外侧设有 6 道抗压肋条以防止水压变形, 底部配备可调金属支架确保水平安置。内部空间分为左侧管道发育区 (50 cm) 与右侧过滤区 (10 cm): 过滤区一侧连接进水管路, 另一侧通过多孔砂滤板与试样隔离, 区内填充砾石以稳定入渗水流; 管道发育区顶部设置密封橡胶层与观察盖板。箱体中部布设 35 根测压管 (编号: A1-A7、B1-B7、C1-C7、D1-D7、E1-E7, 内径为 5 mm, 外径为 7 mm, 高度为 25 cm, 管端包覆滤网), 通过底部预留孔洞与硅胶软管连接, 用于实时




图 3 室内沙箱实验装置设计图 (单位: cm)

Fig.3 Design of the indoor sand box test setup (unit: cm)

监测水头变化。

上游供水系统包括支撑框架与专用供水箱。支撑架设计高度为 2.5 m, 配置定滑轮组、卷扬设备与提升缆绳, 用于精确控制水头高度。供水箱采用独特的双层结构: 内箱(边长为 25 cm 立方体)底部设直径为 6 cm 的进出水口, 外箱(边长为 30 cm 立方体)顶部配置直径为 2 cm 的溢流管。通过协调进出水与溢流控制, 可保持内箱水位恒定, 实现上下游水头差的平稳调节。

下游集水系统采用 100 cm×30 cm×50 cm 的集水槽, 用于收集管涌出口排出的水砂混合物。槽体设有排水管与稳流管双重回路: 排水管直接导流砂箱出水, 稳流管则将上游溢流分流至下游以维持系统水平衡。槽内安装双泵联动作业系统: 在细颗粒未发生侵蚀阶段, 启用小功率循环泵将出水回送至上游供水箱, 实现水资源循环利用; 当监测到颗粒起动侵蚀时, 自动切换大功率排水泵加速泄流。

水头监测系统由测压管组、连接导管、支撑架构及图像采集系统构成。35 根测压管以 5 组阵列形式固定于专用支架, 每管配备 1 m 精密标尺及浮标指示器, 便于直接读数。高清摄像系统全程记录水位波动, 实现水头数据数字化采集。测量时通过硅胶软管(内径为 6 mm, 外径为 10 mm)将测压管与砂箱底部测点连通, 待系统饱和排气后即可获取准确测值。水头计算采用管中水柱高度与位置高程叠加法, 当量程超过 1 m 时, 可通过调整支架高度实现量程扩展。

3.2 试验步骤

本研究开展的试验按以下步骤进行:

(1) 进行设备密封性检测。通过通水检测砂箱及管道连接的密封状况, 确认水流通过时测压管水柱上升并能维持稳定高度, 同时验证供水系统可保持恒定水位。

(2) 试样制备。对土颗粒进行筛分, 选取 9~12 mm 的粗颗粒与 0.100~0.355 mm 的细颗粒, 充分混合后制成试验试样。混合物颗粒级配如图 4 所示, 其不均匀系数 C_u 为 126.97, 曲率系数 C_c 为 0.038。根据颗粒级配对管涌机制影响的相关研究^[33-35], 该试样表现出内部不稳定性, 满足管涌发生的必要条件。

为确保试样均匀压实, 采用分层填筑方式将混合料装入砂箱, 每层铺筑厚度约 10 cm。每层均压实至指定密度后再进行下一层填筑。铺设橡胶垫层后, 采用加压螺栓将盖板与砂箱紧固连接, 同时确保上游供水箱顶面与砂箱保持水平。向砂箱内注水直至淹没试样顶面, 饱和养护 24 h 以排除滞留空气,

并打开测压管三通阀释放水柱中的气体。启动压力传感系统与砂箱摄像系统, 持续记录水位变化及管涌发展过程。试验初期通过逐步提升水箱高度控制上游水位, 单次升幅控制在 3~6 cm。当砂箱内出现可见颗粒运动时立即暂停水位提升, 待状态稳定后继续操作, 直至管道发育停止或根据上游发展距离手动终止试验。




图4 颗粒级配曲线

Fig.4 Particle gradation curve

3.3 试验结果与分析

4 次管涌试验的结果如图 5 所示, 图中清晰展示了主渗流通道的发育过程, 揭示了不同水力梯度下侵蚀模式与水流-土体相互作用机制的演化规律。所有试验中, 主通道均起源于下游管涌出口附近, 并逆水流方向向上游延伸(图 5(a)~5(d)), 呈现典型的逆向侵蚀特征: 管涌出口处的水流集中与压力释放使细颗粒率先启动运移, 促使通道沿最小阻力路径向上游溯源发展。随着侵蚀持续进行, 主通道逐渐趋于平直、拓宽并形成稳定结构, 边界区域粗颗粒充分裸露, 而细颗粒大多被水流带离(图 5(b))。这一现象反映了选择性侵蚀机制, 即细颗粒优先流失形成粗颗粒骨架结构。部分试验中管涌出口附近出现的喇叭形扩口区, 表明该处存在局部渗流集中与水头损失加剧现象。土体非均质性会引发渗流路径偏移, 如图 5(c)中呈现的弯曲或 S 形通道轨迹, 这源于密实度或颗粒分布的局部差异对渗流场的扰动, 导致通道发生横向偏转或分叉现象。此类通道周边粗颗粒的广泛分布, 进一步证实了局部区域颗粒分选作用的强化与渗流稳定性的降低。值得注意的是, 第 4 次试验中出现了勺形通道形态(图 5(d)): 其“勺柄”指向上游水头边界, “勺体”则发育于管涌出口附近。该形态可能源于材料突然失稳或支撑结构塌陷形成的局部冲刷空腔, 标志着逆向侵蚀作用已进入高阶发展阶段。试验中, T 指代从试验开始





(a) 第1组(时间 $T=75$ s)管涌主通道边界图(b) 第2组(时间 $T=84$ s)管涌主通道边界图(c) 第3组($T=86$ s)管涌主通道边界图(d) 第4组($T=84$ s)管涌主通道边界图

图5 BEP 试验管涌主通道示意图

Fig.5 Main channel diagrams for the BEP tests

至管涌主通道稳定形成所经历的时长 (s), 是表征管涌发展速率的关键参数。

3.4 数据集构建

为构建数据集, 本研究采用前述实验室砂箱开展了4组管涌试验, 系统记录了时间 T 、上游水头、实测水头及临界水力梯度等数据。

在非均质含水层管涌数值模拟中, 将下游边界设置为变水头边界, 其余边界定义为隔水边界。管涌出口坐标设定为 (37, 20), 初始水头值为 100 cm,

初始渗透系数为 0.001 6 cm/s, 可动颗粒比例取 0.1, 沉积颗粒比例为 0.05, 临界水力梯度设为 0.032。渗透系数的变化特征表明: 低渗透区对应未受管涌破坏区域, 而高渗透区则与已破坏区域相符。

图6与图7展示了管涌试验的模拟结果。通过对比图5与图7可见, 高渗透区的位置、尺寸及渗





(a) 第1组 ($T=75$ s) 水头场(b) 第2组 ($T=84$ s) 水头场(c) 第3组 ($T=86$ s) 水头场(d) 第4组 ($T=84$ s) 水头场

图6 模拟试验中获得的水头分布场

Fig.6 Head distribution fields obtained from simulation experiments




图7 模拟试验获得的渗透系数场


Fig.7 Permeability coefficient fields obtained from simulation experiments

透系数值均与实测管涌通道结果吻合,表明该动态模型具有良好效能。这套针对非均质含水层管涌通道的数值模拟方法,能够准确提取管涌通道的水头与渗透系数分布场,所构建的数据集可靠适用于神经网络训练。

3.5 BP 与 GA-BP 预测结果对比

为比较 BP 网络与 GA-BP 网络在渗透系数预测中的性能,采用两种模型对第 I 组试验 ($T=75\text{ s}$) 的渗透系数场进行预测,结果如图 8 所示。由图可见,两种模型预测的高渗透区在整体空间分布上均与实际高渗透区吻合,表明两种模型均能有效识别管涌通道的位置及发育模式。

通过对比图 7(a)与图 8 可发现:BP 与 GA-BP 网络在低渗透区表征方面均表现良好,且均能捕捉高渗透区的整体形态与范围,与第 I 组试验 ($T=75\text{ s}$) 的实际结果一致,但仍存在一定差异,尤其在边缘轮廓方面:图 8 红框标示区域显示,在管涌通道上延区域下方出现侵蚀破坏预测,而图 7(a)实际分布中未出现该现象。相比之下,图 8(b)对应区域范围更小,更接近实际情况。

图8 采用神经网络模型得到的试验 I ($T=75\text{ s}$) 预测渗透系数场Fig.8 Predicted permeability fields for test I ($T=75\text{ s}$) using neural network models

此外,红色椭圆区域表明两种模型对管涌出口位置的预测均存在偏差,具体表现为渗透系数值偏低、预测出口尺寸偏小以及通道与出口夹角偏大。但相较于 BP 网络,GA-BP 网络在该区域的预测结果更为精细,呈现出更高的渗透系数值、更丰富的

层状变化以及更清晰的管涌通道分叉特征。

总体而言,GA-BP 网络在渗透系数空间分布预测中展现出更高精度和更优的细节捕捉能力。

由于网络训练采用随机打乱的数据集且网络本身具有随机性,每次训练结果可能存在差异。为更科学地评估 BP 网络与 GA-BP 网络模型的预测性

能,本研究对两种模型采用五折交叉验证策略以检验神经网络模型的泛化能力。每轮验证中选取 4 个子集作为训练集,剩余 1 个子集作为验证集。该过程重复 5 次,通过计算各轮性能指标的平均值来评估模型的预测精度与稳定性。网络设置与前述参数保持一致,评估参数如表 1 所示。

表 1 BP 神经网络与 GA-BP 模型预测精度评价
Table 1 Prediction accuracy evaluation of BP network and GA-BP model

方法	数据集	R^2	MAE	MBE	RMSE
BP	训练集	0.938 (± 0.008)	0.0101 (± 0.001)	0.0019 (± 0.0001)	0.0369 (± 0.002)
	测试集	0.932 (± 0.015)	0.0112 (± 0.001)	0.0019 (± 0.0001)	0.0366 (± 0.002)
GA-BP	训练集	0.953 (± 0.007)	0.0086 (± 0.001)	0.0010 (± 0.0006)	0.0347 (± 0.003)
	测试集	0.952 (± 0.008)	0.0089 (± 0.0006)	0.0016 (± 0.0001)	0.0356 (± 0.002)

注:表中数据为 5 次运行结果的平均值 ($\pm$ 标准差)。

由表 1 可知,GA-BP 模型在预测精度、稳定性和泛化能力方面均优于 BP 模型。测试集平均决定系数 R 达到 0.952,MAE、MBE 和 RMSE 均显著低于 BP 模型,表明预测结果更为精确。各评估指标标准差的减小进一步说明该模型具有更好的稳定性与鲁棒性。此外,遗传算法优化有效避免了局部最优问题,提升了模型收敛速度与预测一致性,展现出更强的泛化能力。

基于上述分析,GA-BP 模型在精度、稳定性和泛化能力方面均优于传统 BP 网络。因此,我们选定 GA-BP 模型作为渗透系数预测的核心算法,并将其应用于后续研究。

4 数据集对 GA-BP 模型精度的影响

4.1 方案设计

在管涌动态模拟中,管涌破坏阶段的数据变异性较高,但在数据集中所占比例较小。这种不平衡

性会影响模型准确表征渗透系数变化的能力,尤其在高渗透区域,其预测偏差更为明显。若采用欠采样方法减少渗透系数变化较小的数据量,可能导致关键信息丢失;而对变化显著数据进行过采样,则会引入噪声并影响模型稳定性。为解决该问题,本研究引入 II、III、IV 组试验的模拟数据以扩充数据集,并探究数据集质量对 GA-BP 网络模型表征精度的影响。训练方案设计如表 2 所示,3 组方案中渗透系数显著变化数据的比例依次递增,从而有效提升数据集质量。

4.2 结果分析

不同训练方案的评估数据如表 3 所示。图 9 展示了各方案的适应度函数变化结果,图 10 呈现了各方案网络表征效果的对比,图 11 则反映了不同方案下损失函数的变化情况。由表 3 可知,经过数据集优化后,方案 1~3 的 R 从 0.95 提升至 0.96,MAE 从 0.009 降至 0.008,MBE 从 0.016 降至 0.015,RMSE

表 2 不同数据集的训练方案设计
Table 2 Design of the training scheme for different datasets

方案	训练集数量	数据来源	快速变化(剧变)的渗透系数		表征结果
			数据占比/%	数据组数	
1	2 000	II ($T=84$ s)	20.3	406	试验 I ($T=75$ s): (H, X, Y, L_H, K)
2	4 000	II ($T=84$ s), III ($T=86$ s)	21.2	848	
3	6 000	II ($T=84$ s), III ($T=86$ s), IV ($T=84$ s)	22.6	1 356	

表 3 不同方案表征精度评估数据
Table 3 Data for assessment of characterization accuracy of different schemes

方案	训练集				测试集			
	R^2	MAE	MBE	RMSE	R^2	MAE	MBE	RMSE
1	0.950 52	0.009 105 2	0.001 625 2	0.035 973	0.948 05	0.008 810 7	0.001 687 6	0.035 757
2	0.957 57	0.008 405 9	0.001 604 1	0.033 833	0.958 16	0.008 341 0	0.001 650 7	0.034 884
3	0.961 29	0.008 089 6	0.001 504 0	0.032 518	0.961 65	0.008 142 2	0.001 486 0	0.032 628




图 9 不同方案的适应度函数
Fig.9 Fitness functions for different schemes




图 10 不同方案的网络预测结果对比
Fig.10 Comparison of network prediction results for different schemes




图 11 不同方案的损失函数
Fig.11 Loss functions for different schemes

从 0.035 降至 0.032。尽管评估参数变化幅度有限，但随着渗透系数显著变化，数据占比的增加，表征精度呈现稳步提升趋势，这表明更均衡、更具代表性的数据集有助于提升网络模型的表征精度。

图 9 显示，各方案的适应度函数均在 20 次迭代

后趋于稳定。随着渗透系数显著变化数据占比的增加，稳定后的适应度值从方案 1 的 0.028 49 降至方案 3 的 0.027 83，说明数据集质量的提升有助于提高遗传算法的优化精度。

图 10 揭示了预测值与实际值之间存在明显的

系统性关联：当渗透系数 $K \leq 1.0 \text{ cm/s}$ 时，模型预测精度较高且偏差较小；而当 $K > 1.0 \text{ cm/s}$ 时，预测误差呈系统性增大趋势，且模型持续低估渗透系数值。这一现象在图 10(a)、10(b)中尤为显著，主要源于方案 1 中训练数据量有限且高渗透样本占比不足。此类数据不平衡问题阻碍了模型对少数类样本的充分学习，进而影响其泛化能力与鲁棒性。随着方案 2(图 10(c)、10(d))和方案 3(图 10(e)、10(f))中数据总量增加及高渗透样本比例提升，该关联性得到部分缓解，但未能完全消除，表明模型在面对极端高渗透条件时仍存在响应迟滞和欠拟合现象。这种系统性的误差关联印证了预测偏差的非随机特性，凸显了训练数据分布对模型性能的重要影响。

图 11 展示了各方案在训练过程中的损失函数收敛曲线。从图中可以看出，3 种方案均能有效收敛至较低水平。结合表 3 中更全面的精度评估指标 (R , MAE , MBE , $RMSE$) 可知，方案 3 在训练集和测试集上均取得了最优的综合性能，表征精度最高。

4.3 结果分析

基于不同训练方案得到的网络模型，对第 I 组试验 ($T=75 \text{ s}$) 的渗透系数分布进行了表征分析，

实际值与表征结果的对比如下。

图 12(a)~12(d)表明，3 种方案均能表征出管涌通道的大致位置与形态特征。随着数据集质量的提升，红色箭头标注的通道下侧侵蚀区域范围逐渐缩小，同时黄色箭头标示的通道内部渗透系数值逐步提高，尤其在通道中心、管涌出口及分叉部位更为明显。通过对比图 12(b)~12(d)与基准图 12(a)可发现：3 种方案中，通道下侧的表征侵蚀区域逐步收敛，管涌出口及通道内部的渗透系数表征值也相应增大。

尽管方案 3 展现出更优的表征性能，但通道中心、管涌出口和分叉点等关键部位的渗透系数值仍存在低估现象，且分层细节表征仍显不足。这些预测误差可能源于以下几方面：①数据分布不均：高渗透区域的样本数量稀缺，导致模型训练更关注整体误差，而在这些区域的拟合精度不足；②模型结构局限：BP 网络适用于连续平滑的函数映射，而高渗透区存在突变特征与强非线性，虽然遗传算法优化了初始权值，但对极端值的表征能力仍受限；③试验误差干扰：渗透系数的量测受水头扰动与波动影响显著，尤其在流速高、波动大的高渗透区域，测量误差会被放大并影响模型对真实规律的学习。




图 12 不同方案对试验 I ($T=75 \text{ s}$) 渗透系数场表征效果

Fig.12 Characterization of permeability coefficient field for test I ($T=75 \text{ s}$) by different schemes

总体而言,随着渗透系数显著变化数据占比的提升,以及数据集趋于均衡完善,GA-BP 网络模型的特征性能呈现持续优化趋势。

5 GA-BP 模型的成像表征与结果分析

基于方案 3 的 6 000 组数据集及优化后的 GA-BP 网络模型,对管涌通道进行了预测与表征(图 13)。试验结束时记录了各测压管的水压值与位置水头值,这些数据为估算砂样表层的渗透系数提供了输入参数。通过 GA-BP 网络模型处理这些输入数据后得到渗透系数预测结果,并进行可视化呈现。输入水头数据如图 14 所示,预测得到的渗透系数场如图 15 所示。




图 13 原始试验的溯源侵蚀河道图

Fig.13 Reverse erosion channel map for the original test




图 14 待输入的水头场分布图

Fig.14 Map of head field to be input




图 15 实际 BEP 渠道的渗透系数场网络表征图

Fig.15 Network characterization of permeability coefficient for actual BEP channel

渗透系数分布云图显示,以高渗区为代表的管涌通道发育趋势与试验结果基本一致,但通道的尺寸和范围仍存在明显偏差。主通道区域的渗透系数值高于未受管涌影响区域,这与实际情况相符。管涌出口处渗透系数较高(0.5~1.0 cm/s),而上游通道区域值较低(0.5~0.8 cm/s),表明对上游通道的表征精度不足。尽管表征结果中存在渗透系数 $K \geq 1.1$ cm/s 的散点,但这些点在云图中未形成集中分布。此外,云图显示管涌通道周围存在一定范围的冲刷区,但对支流通道的进水口的冲刷区域未能实现有效表征。

为更好量化管涌通道范围,以 0.5 cm/s 为边界对图 13 与图 15 的维度数据进行统计(表 4)。结果表明:管涌出口冲刷区范围在 x 轴 28.96~43.23 cm、 y 轴 15.73~30.14 cm 之间,而上游通道冲刷区范围在 x 轴 2.51~28.96 cm、 y 轴 22.71~29.05 cm 之间。高渗区中心与最深点偏移距离为 3.63 cm。相较于实际侵蚀尺寸,GA-BP 网络模型预测的管涌出口较长且较窄,上游通道则较短较窄。同时,高渗中心与实际中心点存在显著偏移,导致主通道整体尺寸出现明显偏差。

表 4 网络模型成像结果的主渠道尺寸对比

Table 4 Comparison of the main channel sizes from network model imaging results

位置	方向	真实范围/cm	表征范围/cm	实际侵蚀尺寸/cm	表征侵蚀尺寸/cm	偏差/cm	结果判定
管涌出口	x	34.9~45.3	28.96~43.23	10.4	14.27	3.87	偏长
	y	11.5~29.0	15.73~30.14	17.5	14.41	-3.09	偏窄
上游渠道	x	3.0~34.9	2.51~28.96	31.9	26.45	-5.45	相对较短
	y	22.0~29.7	22.71~29.05	7.7	6.34	-1.36	偏窄
中心点	x	40.0	38.01	中心点偏移:3.63 cm			偏移过大
	y	20.0	23.04				

在采用 GA-BP 神经网络预测管涌通道的过程中,虽然模型能够准确捕捉通道的整体发育趋势,

但在通道位置、尺度及局部特征方面仍存在偏差。具体表现为:通道形态预测不够精确,高渗透区位

置存在偏移, 以及浅层侵蚀区域识别不足。这些问题可能源于以下几方面局限: ①模型对高渗透区域的准确表征能力有限; ②当前模型验证仅基于 4 组试验数据, 所涵盖的土体条件、水力梯度及颗粒级配范围有限, 制约了模型的泛化能力; ③尽管研究对比了 GA-BP 模型与传统 BP 模型, 但尚未与其他先进机器学习方法进行对比分析, 这需要在后续研究中完善; ④将模型应用于大尺度现场条件时面临显著挑战, 包括环境复杂性增加、数据采集难度增大以及时空变异性的复杂影响。为解决上述问题, 提出以下改进方向:

(1) 增加压力传感器的数量与布设密度, 采用克里金插值或反距离加权插值等方法扩展水头数据, 提升空间覆盖度。

(2) 引入高精度光纤传感器、无线压力传感系统或分布式监测网络, 结合图像监测等多源数据融合技术, 提升数据质量与测量精度。

(3) 应用卷积神经网络 (convolutional neural network, 简称 CNN) 更好处理渗透系数的空间分布特征, 结合 GIS 数据更精确描述通道形态。

(4) 将长短期记忆网络 (long short-term memory, 简称 LSTM) 与 GA-BP 模型相结合, 利用时序数据增强技术提升模型对渗流过程动态演化规律的学习能力。

(5) 扩充试验数据集, 涵盖更广泛的土体条件、颗粒级配与水力梯度, 增强模型泛化性能。

(6) 开展大尺度现场条件下的模型测试, 评估其对复杂环境及可变边界条件的适应性, 并根据现场反馈持续优化模型。

综上所述, 尽管该模型尚未完全考虑管涌的物理机制及多因素耦合作用, 但 GA-BP 网络已展现出良好的预测能力, 可有效支撑管涌灾害识别与风险评估工作, 具有较好的工程应用潜力与实践价值。

6 结 论

本研究聚焦于双层地基条件下的逆向侵蚀管涌现象, 开展了 4 组室内试验。通过非均质含水层管涌数值模拟构建数据集, 并与试验结果进行对比分析。利用砂箱试验提取的数据, 探究快速变化 (剧变) 的渗透系数占比对 GA-BP 模型表征精度的影响, 最终采用优化后的模型对原始管涌通道进行表征。主要结论如下:

(1) 基于非均质含水层管涌数值模拟获得的渗透系数分布场, 在形态和尺寸方面与砂箱试验观测到的主通道高度吻合, 表明通过该方法构建的数据

集具有较高可靠性。

(2) 在优化 GA-BP 网络模型过程中, 制定了 3 种数据占比方案以增强高变异数据集。结果表明: 当渗透系数 $K \leq 1.0 \text{ cm/s}$ 时, 随着数据集规模增大, 表征值与真实值之间的偏差逐渐减小; 而对 $K > 1.0 \text{ cm/s}$ 区间的表征精度仍显不足。

(3) 采用 GA-BP 网络模型对室内试验中的管涌通道进行表征, 发现管涌出口呈现狭长特征, 上游通道则表现为短窄形态, 且高渗中心与实际中心点存在较大偏移。这表明 GA-BP 网络模型能有效表征管涌通道的发育趋势, 但在通道具体位置与尺度方面仍与实际条件存在差异。

综上所述, 本研究为管涌通道表征提供了有益参考, 进一步验证了 GA-BP 网络模型在该领域的应用潜力。

参 考 文 献

- [1] 吴庆华, 张伟, 邬爱清, 等. 堤防管涌险情研究进展[J]. 长江科学院院报, 2019, 36(10): 39-44.
WU Qing-hua, ZHANG Wei, WU Ai-qing, et al. Progress of research on dike pipe surge risk[J]. *Journal of Changjiang River Scientific Research*, 2019, 36(10): 39-44.
- [2] 韩旭, 罗登昌. 长江堤防工程大数据基本特征及应用策略[J]. 人民长江, 2020, 51(增刊 1): 262-264.
HAN Xu, LUO Deng-chang. Basic features and application strategy of big data for Yangtze River embankment engineering[J]. *Yangtze River*, 2020, 51(Suppl.1): 262-264.
- [3] VAN BEEK V M, ROBBINS B A. et al. Use of incipient motion data for backward erosion piping models[J]. *International Journal of Sediment Research*, 2019, 34(5): 401-408.
- [4] WANG Z J, OSKAY C, FASCETTI A. Backward erosion piping in geotechnical infrastructure: a rate process perspective[J]. *Geotechnique*, 2024, 71(2): 255-265.
- [5] MA Z, WANG X, SHANG N, et al. A new numerical method to evaluate the stability of dike slope considering the influence of backward erosion piping[J]. *Water*, 2024, 16(12): 1706-1706.
- [6] RIHA J, PETRULA L. Experimental research on backward erosion piping progression[J]. *Water*, 2023, 15(15): 2749-2749.

- [7] LIU H C, SU H Z, YANG J Q, et al. Multi-fidelity deep neural network with Monte Carlo dropout technique for uncertainty-aware risk recognition of backward erosion piping in dikes[J]. **Applied Soft Computing**, 2024, 112: 112-165.
- [8] Ministry of Water Resources of the People's Republic of China. China water statistical yearbook 2023[M]. Beijing: China Water & Power Press, 2023.
- [9] 朱远祥, 谭君, 陈绪厚. 团洲垸洞庭湖大堤决堤始末: 2 小时的失利, 77 小时的“反攻”[N/OL]. 澎湃新闻. (2024-07-09) [2024-08-18]. https://www.thepaper.cn/newsDetail_forward_27999568
- ZHU Yuan-xiang, TAN Jun, CHEN Xu-hou. The beginning and end of the breach of the Dongting Lake levee at Tuanzhou: a 2-hour defeat, a 77-hour “counterattack” [N/OL]. **The Paper** (2024-07-09) [2024-08-18]. https://www.thepaper.cn/newsDetail_forward_27999568.
- [10] PENG S G, RICE J D. Inverse analysis of laboratory data and observations for evaluation of backward erosion piping process[J]. **Journal of Rock Mechanics and Geotechnical Engineering**, 2020, 12(5): 1080-1092.
- [11] LOPERTE A, BAVUSI M, CERVERIZZO G, et al. Ground penetrating radar in dam monitoring: the test case of Acerenza (Southern Italy)[J]. **International Journal of Geophysics**, 2011(1): 1-9.
- [12] 张建清, 徐磊, 李鹏, 等. 综合物探技术在大坝渗漏探测中的试验研究[J]. 地球物理学进展, 2018, 33(1): 432-440.
- ZHANG Jian-qing, XU Lei, LI Peng, et al. Experimental study of integrated physical exploration technology in dam leakage detection[J]. **Advances in Geophysics**, 2018, 33(1): 432-440.
- [13] 赵汉金, 江晓益, 韩君良, 等. 综合物探方法在土石坝渗漏联合诊断中的试验研究[J]. 地球物理学进展, 2021, 36(3): 1341-1348.
- ZHAO Han-jin, JIANG Xiao-yu, HAN Jun-liang, et al. Experimental study on integrated geophysical methods in the joint diagnosis of seepage in earth-rock dams[J]. **Advances in Geophysics**, 2021, 36(3): 1341-1348.
- [14] GE S L, HU S F, CHEN G X, et al. Characterization of a leaky earth dam using integrated geophysical surveys[J]. **Journal of Applied Geophysics**, 2023, 215(1): 105099.
- [15] QIU H Y, HU R, HUANG Y, et al. Detection and quantification of dam leakages based on tracer tests: a field case study[J]. **Water**, 2022, 14(9): 1448.
- [16] HAMLYN J E, BIRD C L. Geophysical investigation and monitoring of dam infrastructure[J]. **Dams and Reservoirs**, 2021, 31(2): 57-66.
- [17] LIN C H, LIN C P, HUNG Y C, et al. Application of geophysical methods in a dam project: life cycle perspective and Taiwan experience[J]. **Journal of Applied Geophysics**, 2018, 158: 82-92.
- [18] SUN Y D, RU S R. Application of non-destructive testing in reservoir dam safety monitoring[J]. **Environmental & Earth Sciences Research Journal**, 2022, 9(3): 98-103.
- [19] RADZICKI K, STOLIŃSKI M. Seepage monitoring and leaks detection along an earth dam with a multi-sensor thermal-active system[J]. **Bulletin of Engineering Geology and the Environment**, 2024, 83(9): 1-15.
- [20] RANA N M, DELANEY K B, EVANS S G, et al. Application of Sentinel-1 InSAR to monitor tailings dams and predict geotechnical instability: practical considerations based on case study insights[J]. **Bulletin of Engineering Geology and the Environment**, 2024, 83(5): 204.
- [21] RADZICKI K, GOLEBIOWSKI T, CWIKLIK M, et al. A new levee control system based on geotechnical and geophysical surveys including active thermal sensing: a case study from Poland[J]. **Engineering Geology**, 2021, 293: 110-120.
- [22] 翟越, 刘浪, 于澍. 堤防管涌发生可能性识别的网格搜索-支持向量机方法[J]. 中南大学学报(自然科学版), 2015, 46(4): 1497-1503.
- ZHAI Yue, LIU Lang, YU Shu. Grid search-support vector machine method for identifying the possibility of dike piping occurrence[J]. **Journal of Central South University (Science and Technology)**, 2015, 46(4): 1497-1503.
- [23] 饶小康, 马瑞, 张力, 等. 基于 GIS+BIM+IoT 数字孪生的堤防工程安全管理平台研究[J]. 中国农村水利水电, 2022(1): 1-7.
- RAO Xiao-kang, MA Rui, ZHANG Li, et al. Research on safety management platform for dike engineering based on GIS+BIM+IoT digital twin[J]. **Rural Water**

- Conservancy and Hydropower in China**, 2022(1): 1-7.
- [24] LU G Y, OUYANG P, CHENG Y, et al. Intelligent identification method for dike piping monitoring based on YOLO model[J]. **Advances in Water Science and Hydropower Engineering**, 2024, 44(1): 89-94.
- [25] BAND S S, JANIZADEH S, SAHA S, et al. Evaluating the efficiency of different regression, decision tree, and Bayesian machine learning algorithms in spatial piping erosion susceptibility using ALOS/PALSAR data[J]. **Land**, 2020, 9(10): 346.
- [26] DING S F, SU C Y, YU J Z. An optimizing BP neural network algorithm based on genetic algorithm[J]. **Artificial Intelligence Review**, 2011, 36: 153-162.
- [27] CAO M H, NIE Z L, SONG L, et al. GABP-based multiparameter identification for permanent magnet synchronous linear motors[J]. **Journal of Power Electronics**, 2024, 24(9): 1428-1437.
- [28] LI B W, SHEN L G, ZHAO Y, et al. Quantification of interfacial interaction related with adhesive membrane fouling by genetic algorithm back propagation (GABP) neural network[J]. **Journal of Colloid and Interface Science**, 2023, 640(1): 110-120.
- [29] XIE J Y, ZHENG J C, BAI L. Model for restoring obstructed beam transmission in atmospheric turbulence based on BP neural network[J]. **Physics Letters A**, 2024, 130030.
- [30] ZHANG J, LIU L, WANG L, et al. Fault detection of key parts of wind turbine based on BP neural network combination prediction model[J]. **Energy Informatics**, 2024, 528: 124-124.
- [31] LI X N, CHENG X, WU W J, et al. Forecasting of bioaerosol concentration by a back propagation neural network model[J]. **Science of the Total Environment**, 2020, 698: 134315.
- [32] LIANG Y, YEH T C J, WANG Y L, et al. Numerical simulation of backward erosion piping in heterogeneous fields[J]. **Water Resources Research**, 2017, 53(4): 3246-3261.
- [33] 倪小东, 寇绮, 左翔宇, 等. 基于透明土技术与颗粒流方法联合开展管涌细观机理研究[J]. **水利学报**, 2021, 52(12): 1482-1497.
- NI Xiao-dong, KOU Heng-qi, ZUO Xiang-yu, et al. Research on the microscopic mechanism of piping based on transparent soil technology and particle flow method[J]. **Journal of Hydraulic Engineering**, 2021, 52(12): 1482-1497.
- [34] 姚志雄, 周健, 张刚, 等. 颗粒级配对管涌发展的影响试验研究[J]. **水利学报**, 2016, 47(2): 200-208.
- YAO Zhi-xiong, ZHOU Jian, ZHANG Gang, et al. Experimental study on the influence of particle gradation on piping development[J]. **Journal of Hydraulic Engineering**, 2016, 47(2): 200-208.
- [35] 康捷, 任杰, 南胜豪, 等. 形状效应下砂土管涌试验及水力条件分析[J]. **水力发电学报**, 2023, 42(5): 97-106.
- KANG Jie, REN Jie, NAN Sheng-hao, et al. Experimental study and hydraulic condition analysis of piping in sand under shape effect[J]. **Journal of Hydroelectric Engineering**, 2023, 42(5): 97-106.