

# 基于 Transformer 模型堤坝渗漏入口精准识别方法研究

梁 越<sup>1,2</sup>, 赵 硕<sup>\*2</sup>, 喻金桃<sup>3</sup>, 许 彬<sup>1,2</sup>, 张 斌<sup>2</sup>, 龚胜勇<sup>2</sup>, 舒云林<sup>2</sup>

(1.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; 2.重庆交通大学河海学院, 重庆 400074;

3.中交第四航务工程勘察设计院有限公司, 广东 广州 510000)

**摘要:** 渗漏是堤坝工程面临的主要安全隐患, 渗漏入口精确识别与定位对降低堤坝风险至关重要。通过堤坝渗漏入口示踪剂分布及其运移特征模拟数据, 训练学习 Transformer 模型以确定最优参数条件并分析该条件下该模型的预测效果, 进一步通过室内模型试验验证该模型的可靠性。研究表明: (1) 当迭代次数达 600 次时, 模型预测的流速最大值相对误差最小, 且最大流速值坐标与真实渗漏入口坐标最为接近, 预测效果最佳; 在此条件下, 当数据采集时长为 50 秒时, 模型预测的流速最大值相对偏差最小, 预测效果最优。(2) 在最佳迭代次数和数据采集时长条件下, 模型预测精度超过 95%, 渗漏入口大小和渗漏流量的预测值与真实值差异极小, 且流速和位置预测相对误差均较低, 其中位置预测相对误差低于 5%。(3) 将电导率试验采集数据转换为示踪剂浓度并输入至该模型进行流速分布预测, 可知该模型能准确定位渗漏入口位置, 且流速和渗漏入口坐标的预测平均相对误差均低于 10%, 进而验证了该模型在渗漏入口定位中的有效性与准确性。相关研究成果可为堤坝渗漏入口精确定位奠定理论基础和提供技术支撑。

**关键词:** 堤坝; 渗漏入口; Transformer 模型; 精准识别; 室内模型试验

中图分类号: TV698.1+2 文献标识码: A

作者简介: 梁越(1985—),男,教授,博士,主要从事水利工程灾变机理及防治技术等方面的教学与科研工作。E-mail: liangyue2560@163.com。

## Research on accurate identification method of seepage inlet of embankment dam based on Transformer modeling

LIANG Yue<sup>1,2</sup>, ZHAO Shuo<sup>\*2</sup>, YU Jintao<sup>3</sup>, XU Bin<sup>1,2</sup>, ZHANG Bin<sup>2</sup>, GONG ShengYong<sup>2</sup>, SHU Yunlin<sup>2</sup>

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

School of River and Ocean Engineering, Chongqing Jiaotong University, Chongqing 400074, China; 3. CCCC Fourth Harbor Engineering Survey and Design Institute., Guangzhou 510000, China)

**Abstract:** Leakage is a significant safety hazard for embankment dams, and accurate identification and localization of leakage inlets are crucial for reducing dam risk. Using simulated tracer distribution and transport data of leakage inlets, we trained a Transformer model to determine optimal parameter conditions and evaluate its predictive performance. The model's reliability was further verified through indoor experiments. The study found that: (1) when the number of iterations reaches 600, the relative error in the predicted maximum flow velocity is minimized, and the coordinates of the predicted maximum flow velocity are closest to those of the actual leakage inlet. Under this condition, when the data collection time is 50 seconds, the relative deviation in the predicted maximum flow velocity is also minimized, resulting in the best prediction. (2) With the optimal number of iterations and data collection time, the model achieves more than 95% prediction accuracy. The predicted values for leakage inlet size and flow rate are close to the actual values, with low relative errors in flow rate and location predictions. The relative error in location prediction is less than 5%. (3) Data from conductivity tests were converted into tracer concentrations and input into the model to predict flow velocity distribution. The model accurately locates the leakage inlet, with average relative errors in predicting flow velocity and inlet coordinates below 10%, confirming the model's validity and accuracy in locating leakage inlets. These findings lay the theoretical foundation and provide technical support for the accurate identification of leakage inlets in embankment dams.

基金项目: 国家自然科学基金面上项目(52379097); 重庆市研究生联合培养基地建设项目(JDLHPYJD2021004); 重庆市技术创新与应用发展专项基金项目(CSTB2022TIAD-GPX0045); 重庆市水利科技重点项目(CQSLK - 2024005); 重庆市博士后科学基金项目(CSTB2023NSCQ-BHX0223)

收稿日期:

\*通信作者(E-mail: 17832096350@163.com)

**Key words:** dam; leakage ingress; Transformer model; precise identification; laboratory-scale model experiment

## 0 引言

随着我国水利工程建设的不断发展<sup>[1]</sup>, 建成的水库大坝数量逐年增多, 截至目前, 我国共建成水库大坝 98000 多座, 但我国现运行的大坝、堤防中, 30% 是由渗漏引起的。堤坝的渗漏会造成水库水量损失, 甚至干枯, 更重要的是, 随着渗漏入口的不断发展, 会导致坝体产生塌滑和不均匀沉陷, 进而威胁堤坝的安全稳定, 严重者甚至发生堤坝溃决等重大险情<sup>[2-3]</sup>。堤坝渗漏入口的精准识别对于确保堤坝安全和保护下游区域免受洪水灾害至关重要。目前应用较广的渗漏入口探测方法, 如探地雷达法、高密度电法等。但探地雷达法不适合较大深度的探测, 且容易受金属和人工磁场的干扰; 高密度电法容易受到地形地貌条件的限制<sup>[4]</sup>。因此, 如何有效精准识别水库大坝渗漏隐患<sup>[5-7]</sup>对保障大坝安全运行具有重要意义<sup>[7-11]</sup>。

近年来, 随着计算机技术的快速发展, 深度学习技术<sup>[12-13]</sup>被逐渐应用于各个领域, 尤其在渗漏识别方面的应用取得了较好的成果<sup>[14-16]</sup>。黄宏伟和李庆桐<sup>[17]</sup>基于全卷积网络的盾构隧道渗漏水病害图像识别算法对渗漏水病害进行快速精准的识别诊断, 并有效地避免干扰物的影响。武建华等<sup>[18]</sup>提出一种基于轻量化卷积神经网络 MobileNet-SSD 的变电站设备油液渗漏的识别定位方法, 在保证准确率和召回率在工程应用允许范围之内同时, 大大减小了模型的参数大小, 提升了模型的计算效率。陈前<sup>[19]</sup>从深度、宽度以及注意力三个层面对深度学习中多种典型卷积神经网络结构进行了研究, 并选择效果最优的 AM-VGG16 结构来进行隧道渗漏水的特征识别。基于深度学习的渗漏识别方法相较其他检测方法具有更加出色的自动化水平、特征提取能力<sup>[20]</sup>以及处理复杂的数据, 因此具有更好的识别精度。人工智能正在迅速成为各个领域的主流趋势, 机器学习方法凭借其强大的数据处理能力和自我学习能力, 逐渐成为进行高效、准确识别的必然选择。基于 Transformer 模型的方法在渗漏入口的精准识别中将通过自注意力机制, 可以更好地捕捉数据中的重要特征, 提高了识别的准确性和效率。因此, 特别是在堤坝管理中, 采用机器学习方法来进行识别不仅符合技术发展的趋势<sup>[21]</sup>, 也是应对现代复杂识别需求的必然要求。

本文将结合理论分析、Transformer 模型、数值模拟、室内模型试验等手段利用 Fluent 模拟的不同工况下示踪剂分布及运移特征生成数据集, 结合 Transformer 模型的训练并通过试验加以验证, 实现对

堤坝渗漏入口的精准识别。将重点对 Transformer 模型进行训练, 精准识别数据中的规律和特征, 并生成对应的映射关系, 从而定位渗漏入口的相关信息, 并利用室内模型试验来进一步验证 Transformer 模型的可行性。

## 1 模型训练学习及精度分析

### 1.1 Transformer 模型概况

Transformer 模型<sup>[22]</sup>是一种基于自注意力机制的深度学习架构, 首次由 Vaswani 等<sup>[23]</sup>人在 2017 年提出, 它通过并行处理输入序列的不同部分, 利用自注意力机制捕捉长距离依赖关系, 避免了传统递归神经网络的顺序处理限制。Transformer 模型的完整结构如图 1 所示。Transformer 模型的关键组件包括编码器 (Encoder) 和解码器 (Decoder)。编码器负责接收输入序列并将其转换为隐含的表示; 解码器则根据这些表示生成输出序列。这种结构使得 Transformer 模型在处理序列任务时能够同时理解输入和生成输出。

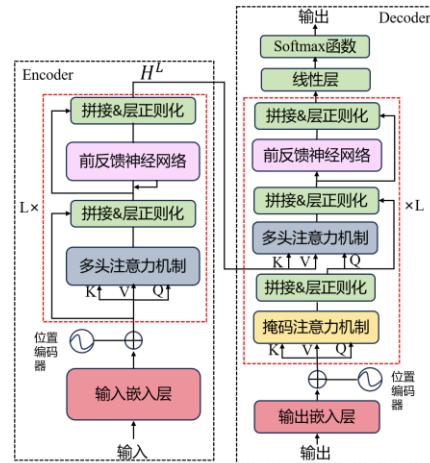


图 1 Transformer 完整网络结构图<sup>[24]</sup>

Fig. 1 Transformer complete network architecture diagram

自注意力机制是 Transformer 模型的核心, 而多头注意力机制由多个自注意力机制组成。自注意力机制的公式如下:

$$\text{Attention}(q, k, v) = \text{soft max}\left(\frac{qk^T}{\sqrt{d_k}}\right)v \quad (1)$$

式中  $q$ ,  $k$ ,  $v$  分别为查询矩阵, 键矩阵, 值矩阵;  $d_k$  代表向量  $k$  的特征维度。

自注意力机制允许 Transformer 模型在处理输入数据时, 能够关注序列中所有元素的关系。对于堤坝渗漏入口识别, 这意味着模型可以同时考虑所有监测

点的数据, 而不仅仅是局部区域。这种全局关注能力使得模型能够有效处理复杂的输入数据和长序列依赖, 提高识别精度和效率。

## 1.2 Transformer 模型训练学习

### (1) 数据集的生成

本研究中, Transformer 模型的训练数据集来源于数值模拟软件 Fluent (2022 R1) 对存在渗漏入口的水箱壁面进行示踪剂分布及运移模拟的仿真结果, 即通过探究示踪剂在渗漏入口规模、示踪剂投放位置及示踪剂投放量等不同工况下的分布及运移规律, 从而为 Transformer 模型的训练学习提供数据基础。首先, 在 Fluent 软件的 Geometry 模块中构建一个尺寸为  $600 \times 600 \times 60 \text{ mm}^3$  的水箱模型(见图 2), 并在渗漏入口周围的  $400 \times 400 \text{ mm}^2$  范围内设定示踪剂投放位置。接着, 在 Mesh 模块中进行网格划分, 设定最小面网格为  $0.003 \text{ m}$ , 最大面网格为  $0.03 \text{ m}$ , 几何结构设定为没有空隙的流体区域。

在模型选择界面, 采用标准的 K-epsilon(2eqn)模型, 壁面函数选用标准壁面函数, 并在组分模型中选择组分传递。材料设置中, 去除氧气、氮气等无关材料, 只保留水和盐水。在边界条件设置中, 模拟设有两个入口和一个出口, 其中 inlet1 为示踪剂投放入口(质量流入口), 其质量流率设置为  $0.01 \text{ kg/s}$ , 以通过调整投放时间或速度以模拟不同示踪剂投放量。周围环境设为压力入口 inlet2, 仅用于补充水。而出口则为质量流出口, 位于壁面中心, 根据出流规模设置不同的质量流速率。

运算设置中, 步长设为  $0.005 \text{ s}$ , 并进行预模拟以确定模拟时长为  $50 \text{ s}$ , 此时壁面上示踪剂质量分数达到约  $10^{-3}$  量级的最大值。考虑到实际工程中传感器无法直接采集示踪剂浓度, 推测水体中的示踪剂已完全流出或稀释。最终设置步数为 10000 步, 最大迭代数为 10。通过改变渗漏规模或示踪剂投放位置与渗漏入口间的距离来模拟不同的渗漏工况, 从而收集并分析了各种工况下壁面示踪剂浓度与水流速度的数据, 形成了 Transformer 模型的学习训练数据集。

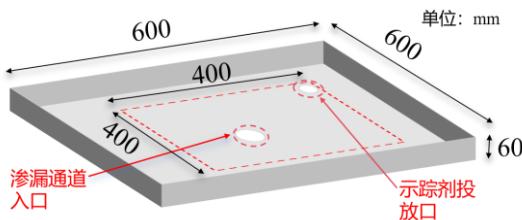


图 2 几何模型

Fig. 2 Geometric model

### (2) 分集和设置超参数

将考虑了渗漏规模、示踪剂投放位置与渗漏入口间距离大小以及示踪剂投放量不同工况下模拟数据的 80% 划分为训练集, 剩下 20% 划分为测试集。

网络参数经贝叶斯优化<sup>[25]</sup>后, 以实现最佳的采集效果。Transformer 模型参数设置为: 隐藏层 1 为 256, 隐藏层 2 为 512, dropout 设为 0.1, 即在训练过程中随机丢失神经元的概率为 0.1, 作用是防止网络过拟合。学习率为 0.01, 即在优化器更新网络参数时, 每次参数更新的步长为 0.01。

## 1.3 最优参数的确定

为了确定 Transformer 模型中的最优参数, 分别改变迭代次数和数据量的采集长度来对流场中的速度场进行预测。

### (1) 最优迭代次数

通过引入相对误差, 对 Transformer 模型预测程度的精确性进行评判。下式(2)、(3)分别是流速相对误差( $R_V$ )和渗漏入口定位的相对误差( $R_W$ )的计算公式。当  $R_W \leq 5\%$ , 认为渗漏入口定位效果较好。

$$R_V = \frac{V_{\text{预}} - V_{\text{真}}}{V_{\text{真}}} \times 100\% \quad (2)$$

$$R_W = \frac{L_1}{L_{\text{模型边长}}} \times 100\% \quad (3)$$

式中,  $L_1$  指的是预测点至真实渗漏入口中心的距离, 单位米。

表 1 是 Transformer 模型在 50、100、200、400、600 不同迭代次数下, 模型预测的壁面流速最大值与壁面真实流速的最大值对比关系及坐标。从表 1 可算得, 当迭代次数从 50 增加到 600 时, 速度预测的相对误差分别是 19.89%、2.16%、10.34%、2.81% 和 0.36%, 逐渐降低。在迭代次数为 50 和 100 时, 速度最大值的坐标分别为 (0.286, 0.282) 和 (0.284, 0.289), 与渗漏通道入口中心的距离分别为 0.023 m 和 0.0194 m, 相对误差分别为 3.83% 和 3.23%, 均大于 2.5%, 存在较大的定位误差。随着迭代次数增加, 预测的速度最大值点逐渐接近通道中心。迭代 200、400 和 600 时, 速度最大值的点距离通道入口中心分别为 0.01 m、0.0054 m 和 0.0022 m, 相对误差分别为 1.67%、0.9% 和 0.37%, 均小于 2.5%, 表明定位在渗漏通道入口范围内。由此可见, 迭代 600 次时, Transformer 模型的预测更为精准。

表 1 不同迭代次数下 Transformer 模型预测的壁面流速最大值

Table 1 Maximum values of wall flow velocity predicted by

Transformer model for different number of iterations

迭代次数	速度(m/s)	中心坐标
真实值	0.4725	(0.300, 0.300)
50 次	0.3786	(0.286, 0.282)
100 次	0.4623	(0.284, 0.289)
200 次	0.4237	(0.290, 0.300)
400 次	0.4593	(0.295, 0.298)
600 次	0.4708	(0.301, 0.302)

图 3 是 Transformer 模型对壁面上流速最大值预测值相较于真实值之间的相对误差变化。由图 3 可知, 随着迭代次数的增加, 速度最大值预测值的相对误差呈降低的趋势, 当迭代次数为 600 时最为接近 0。图 4 是 Transformer 模型在不同迭代次数下预测出的渗漏入口中心与实际入口中心间距离的相对误差变化。由图 4 可见, 随着迭代次数的增加, 相对误差逐渐变小, 预测出的渗漏入口中心更加靠近真实的渗漏入口中心, 说明迭代次数增加有助于对渗漏入口的精准定位。故在后续讨论数据采集时长对 Transformer 模型性能影响时, 选择最优迭代次数为 600 进行性能分析。

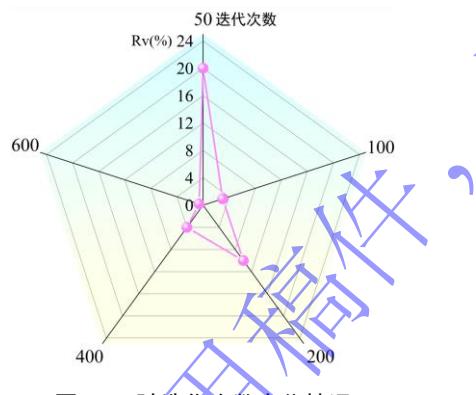


图 3 Rv 随迭代次数变化情况

Fig. 3 Variation of Rv with the number of iterations

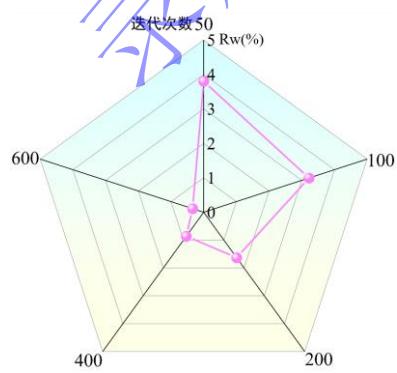


图 4 Rw 随迭代次数变化情况

Fig. 4 Variation of Rw with the number of iterations

## (2) 最优数据长度

在最优迭代次数条件下, 表 2 是 Transformer 模型分别在 30、40、50 s 不同数据采集时长下预测的壁面流速最大值及中心坐标。

表 2 不同数据采集时长下模型预测的壁面流速最大值及坐标

Table 2 Maximum values and coordinates of wall flow velocity predicted by the model for different data collection durations

采集时长	速度(m/s)	中心坐标
真实值	0.4725	(0.300, 0.300)
30s	0.3983	(0.291, 0.286)
40s	0.6013	(0.287, 0.307)
50s	0.4708	(0.295, 0.308)

图 5 是最优迭代次数下, 数据采集时长不同时, Transformer 模型对壁面上流速最大值预测值的相对误差变化。图 6 则是在不同数据采集长度情况下, Transformer 模型预测出的渗漏入口中心距离真实的渗漏入口中心距离的相对误差变化。

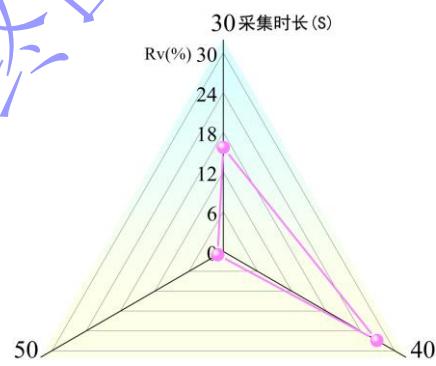


图 5 Rv 随数据长度变化情况

Fig. 5 Variation of Rv with data length

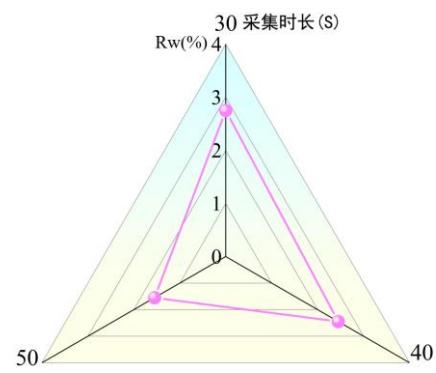


图 6 Rw 随数据长度变化情况

Fig. 6 Variation of Rw with data length

由图 5 可知, 数据采集长度的增加至 50 s 时, Transformer 预测出的壁面流速最大值的相对误差最接近于 0。由图 6 可知, Transformer 随着数据采集长度的增加, 相对误差逐渐减小, 且均小于 3%, 50 s 时达到最小。故在后续对 Transformer 模型预测结果分析

时, 选取最佳数据采集长度为 50 s 时进行模型性能分析。

#### 1.4 Transformer 模型精准识别性能分析

本次模型性能分析中引入渗漏规模指标, 对 Transformer 模型最优参数条件下的预测效果进行进一步的精准识别性能分析。

Transformer 模型在其最优参数条件下对同一工况的预测结果的可视化, 其中, 图 7 (a) 是实际的流速云图, 图 7 (b) 是 Transformer 模型预测的结果。从图 7 中 (a) 和 (b) 流速最大值所在位置对比可见, 最大值位置与真实值非常接近, 能对壁面流速分布进行较好的预测, 从而对渗漏入口进行精准定位。

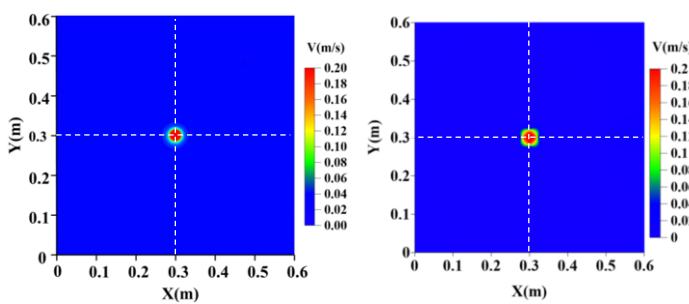


图 7 Transformer 模型最优条件下预测效果对比

Fig. 7 Comparison of prediction effects under optimal conditions of Transformer models

表 3 展示了 Transformer 模型在其最优参数条件下, 渗漏入口内流速预测结果的平均值及入口大小。图 8 是 Transformer 模型对流速预测和位置预测的相对误差图。由表 3 中模型对渗漏入口面积和流量预测值可知, Transformer 模型预测的渗漏入口大小为  $6.894 \text{ cm}^2$ , 其与真实值仅相差  $0.171 \text{ cm}^2$ , 渗漏流量与真实渗漏流量也相当接近, 相差仅在  $16 \text{ cm}^3/\text{s}$  左右。从图 8 中可见 Transformer 模型对流速预测和位置预测的相对误差均较低, 且位置预测相对误差低于 5%, 综合来看, Transformer 模型能对渗漏入口进行精准定位。

表 3 Transformer 模型预测结果

Table 3 Components of cement and industrial residues

	平均流速 (cm/s)	入口面积 (cm <sup>2</sup> )	流量 (cm <sup>3</sup> /s)	坐标 (m)
真实值	28	7.065	197.82	(0.3, 0.3)
Transformer 预测效果	30	6.894	206.82	(0.31, 0.29)

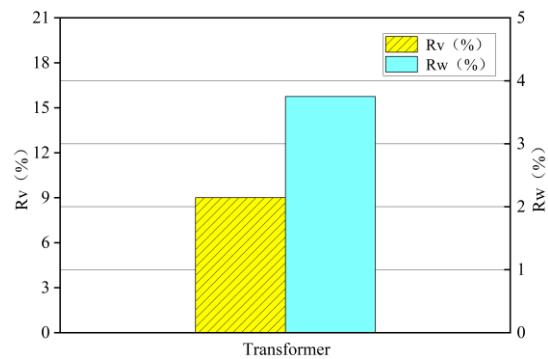


图 8 Transformer 模型的 Rv 和 Rw

Fig. 8 Transformer model of Rv and Rw

## 2 室内模型试验验证

### 2.1 试验设备

如图 9 所示, 试验设备主要包含电导率数据采集系统、示踪剂投放控制装置以及渗漏模型装置。

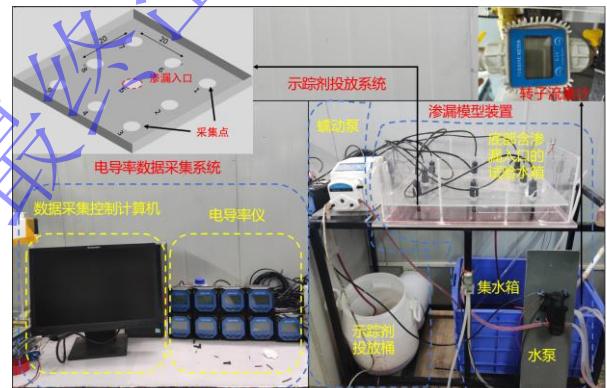


图 9 试验设备

Fig. 9 Testing equipment

(1) 电导率数据采集系统由数据采集控制计算机和电导率仪组成, 计算机利用程序控制系统并实时记录电导率数据; 电导率仪通过连接在渗漏壁面各采集点的石墨探头可以实时显示该点的电导率值, 并传送至 PC 端, 本次实验采集频率设置为 200 ms/次, 数据储存时间间隔同样为 200 s, 图 10 (a)、(b) 分别电导率仪、电导率探头。

(2) 示踪剂投放装置主要由示踪剂存放桶和蠕动泵组成。蠕动泵采用慧宇 BT100J-1A 型蠕动泵, 如图 10 (c) 所示, 该蠕动泵的转速范围为 0.1-100 rpm, 对应的流量范围为 0.0002-210 ml/min, 可用来调节示踪剂的投放速度和投放量。

(3) 渗漏模型装置主要由上部渗漏水箱、水泵及下部集水箱组成。上部渗漏水箱长×宽×高为 60 cm × 60 cm × 80 cm。水泵通过改变不同的吸力 (即增加或者减少水泵数量) 来实现不同的出流流量, 以模拟

不同大小的渗漏规模。转子流量计则是实时监测流量数据的大小。下部集水箱主要是用来对实验水体的收集，以便后续作统一处理。



(a) 电导率仪 (b) 电导率探头 (c) 蠕动泵

图 10 电导率采集设备及示踪剂投放设备

Fig. 10 Conductivity acquisition equipment and tracer delivery equipment

## 2.2 工况设计

电导率表示溶液传导电流的能力，单位为西门子每米 (S/m)。在本试验中，主要通过采集壁面各点的电导率来推算出对应点及整个坝面的浓度，从而代入识别模型中预测壁面流场流速分布，并以此来确定渗漏通道入口位置以及渗漏流量，通过对真实渗漏入口位置和真实渗漏流量来判断 Transformer 模型识别的精确度。

在正式开展试验之前，开展预试验设置了 26 组不同浓度盐溶液，测得电导率与盐溶液之间存在明显的线性关系，电导率与浓度关系如图 11 所示。试验过程主要探究当示踪剂投放点与渗漏入口间距离分别为 15 cm、20 cm、25 cm 工况时，Transformer 模型对壁面流场流速的预测、渗漏入口面积及渗漏入口位置和真实值间的差距。

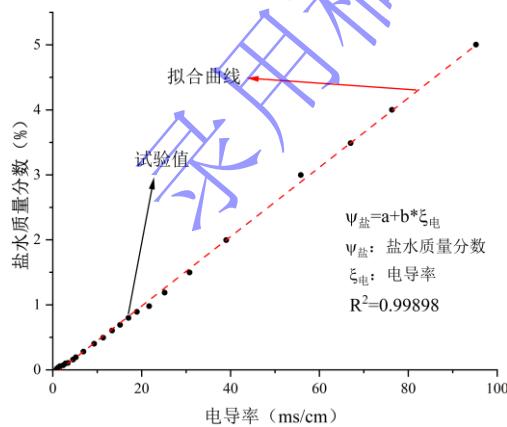


图 11 溶液浓度与电导率关系图

Fig. 11 Relationship diagram between solution concentration and conductivity

## 2.3 试验流程

### (1) 电导率校准及传感器标定

将电导率探头完全插入 1413 us/cm 电导率校准液中，点击电导率仪菜单选项中的在线标定选项，待在线标定页中下方实测数据稳定时，按下确认键即可完成在线标定工作。

### (2) 配置示踪剂若干瓶

实验中的示踪剂由 NaCl 含量大于 99.5% 的分析纯氯化钠和自来水配置而成。

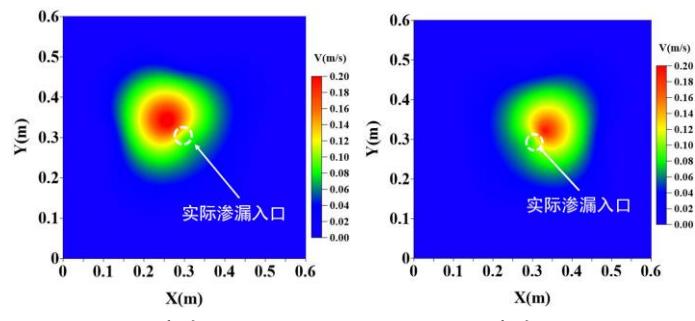
(3) 在试验前准备工作准备好后，正式开始试验。打开水龙头，将试验水箱注满水，打开渗漏入口开关（即水泵），待水位平稳后打开电导率采集界面，开始采集电导率。随后立即打开示踪剂投放系统中的蠕动泵开关，开始注入示踪剂，待示踪剂投放量达到试验设计值后关闭蠕动泵，并停止示踪剂投放。待水箱中各点电导率值与自来水导率相近时，就可认为渗漏壁面不再存在示踪剂，即可停止采集。实验前要调节水龙头注水速率与水泵吸水速率一致，以保证水箱中水位的平稳。

### (4) 其他工况重复步骤 (3) 即可。

## 2.4 Transformer 模型预测结果及精度分析

为了验证 Transformer 模型预测识别效果是否精准可靠，通过室内试验采集得到电导率转化为示踪剂质量分数，并将其代入至 Transformer 模型中预测壁面流速分布，通过预测结果和真实结果间的对比，评价 Transformer 模型在实际应用中的预测识别精度和方法的可行性。

通过分析改变示踪剂投放点与渗漏入口间距离时的试验工况来评价 Transformer 模型。图 11 (a)~(d) 是改变示踪剂投放点与渗漏入口间距离的情况下，Transformer 预测模型对壁面流速分布预测结果可视化以及相对误差变化的对比，中间白圈为实际渗漏入口位置。表 4 是 Transformer 模型预测的壁面最大流速及其坐标点。



(a) 距离为 15 cm

(b) 距离为 20 cm

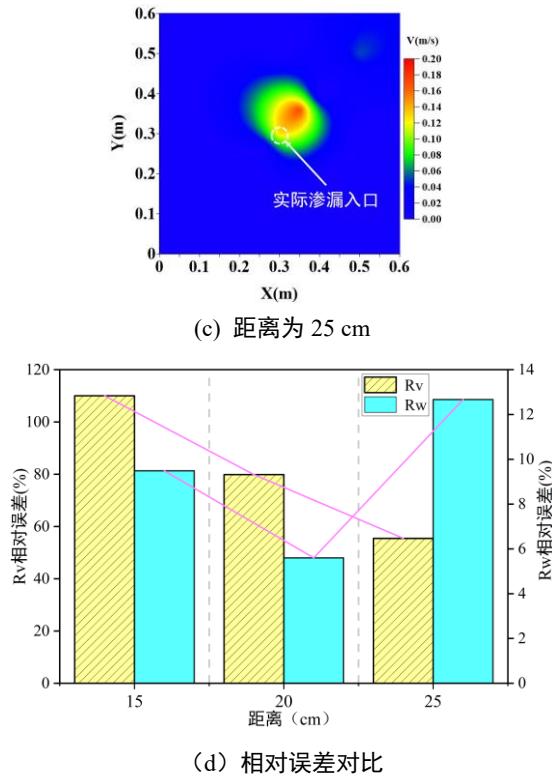


图 12 不同距离下 Transformer 的预测效果

Fig. 12 Prediction effect of Transformer at different distances

表 4 不同距离下 Transformer 模型预测的壁面流速最大值

Table 4 Maximum values of wall flow velocity predicted by

Transformer model at different distances

距离(cm)	速度 (cm/s)	入口面积 (cm <sup>2</sup> )	坐标 (m)
真实值	11	7.58	(0.30, 0.30)
15 cm	23.14	25.06	(0.26, 0.34)
20 cm	19.87	14.1	(0.33, 0.32)
25 cm	17.12	8.28	(0.35, 0.36)

由图 11 (d) 可知, Transformer 模型预测的壁面流速相对误差分别为 110.4%、80.6% 和 55.6%, 速度预测的平均相对误差为 82.2%; 经过表 4 计算发现, 预测渗漏规模分别达到了 580、280 和 142 cm<sup>3</sup>/s。此外, 经过计算发现距离由 15 cm 增加至 25 cm 过程中, 预测的渗漏入口中心与实际渗漏入口中心的距离分别为 5.66、3.61 和 7.81 cm, 位置预测的相对误差分别为 9.43%、6.01% 和 13.02%, 位置预测的平均相对误差为 9.49%, 相对误差较低, 对渗漏入口定位预测效果较为精准, 预测结果可以为渗漏入口定位提供数据支撑。表 4 中预测误差随距离变化波动, 可能在距离 20 cm 时, 实验的示踪剂分布与渗漏入口的流场特性更匹配, 从而使得模型预测的输入数据更贴近实际情况, 导致误差降低。

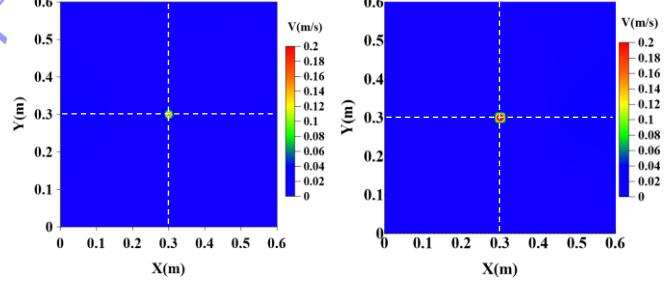
### 3 讨 论

在本文中, 我们提出了一种基于 Transformer 模型的堤坝渗漏入口精准识别方法, 与传统的网络模型 DNN 和 XGBoost 模型预测效果相比, Transformer 模型的预测结果更为精准。图 12 (a)、(b) 为 DNN 和 XGBoost 模型在其最优条件下对同一工况的壁面流速预测可视化。表 5 为 Transformer、DNN 以及 XGBoost 模型在其最优条件下, 对渗漏入口内流速预测结果的平均值及入口大小。

表 5 不同网络模型预测效果对比

Table 5 Prediction performance of DNN and XGBoost network models

	平均流速 (cm/s)	入口面积 (cm <sup>2</sup> )	流量 (cm <sup>3</sup> /s)	坐标 (m)
真实值	28	7.065	197.82	(0.3, 0.3)
Transformer 预测效果	30	6.894	206.82	(0.31, 0.29)
XGBoost 预 测效果	24	1.246	29.9	(0.32, 0.33)
DNN 预 测效果	28	1.358	38.024	(0.35, 0.34)



(a) XGBoost 预测流速分布

(b) DNN 预测流速分布

图 13 DNN 模型和 XGBoost 模型最优条件下流速预测

Fig. 13 Flow velocity prediction under optimal conditions using DNN model and XGBoost model

由表 5 可知, Transformer 模型预测的渗漏入口大小 (6.894 cm<sup>2</sup>) 与实际入口大小 (7.065 cm<sup>2</sup>) 更为接近, 其余两个模型预测的入口大小明显小于实际入口大小, 预测效果欠佳。且 DNN 和 XGBoost 模型预测的渗漏流量远低于真实渗漏流量, 而 Transformer 模型预测的渗漏流量虽高于真实渗漏流量, 但十分接近, 相差仅在 16 cm<sup>3</sup>/s 左右, 反观 DNN 和 XGBoost 模型预测得到的流量分别相差 152 和 161 cm<sup>3</sup>/s 左右, 所以 Transformer 模型在预测渗漏入口大小和流量特征方面的表现展示了其卓越的能力, 与传统方法相比有明显改进。图 8、图 12 以及图 13 中的数据比较进一

步凸显了 Transformer 模型的优势。Transformer 模型在位置预测方面的相对误差保持在 5%以下，预测更为准确。综上所述，Transformer 模型凭借其自我注意机制和长距离依赖捕捉能力，相较于传统的网络模型，能够对渗漏流速和入口进行精准的定位。

本文通过数值模拟和室内模型试验，建立并验证了 Transformer 模型对渗漏入口识别的可行性。但是仍然存在诸多局限性，如未考虑复杂工况（复杂的地质分布、多渗漏点干扰等）适用性分析；流速和示踪剂分布是反映渗漏过程的关键物理变量，但忽略其他关键变量（如地层渗透系数、水压梯度等）的情况以及结合实际渗漏工程实例进行研究，这些因素均可能限制模型在实际复杂工程中的应用范围。未来可通过模型压缩和分布式计算实现自注意力机制处理复杂监测数据，通过模型优化（如轻量化、并行计算等）提升实时性与计算效率，为 Transformer 模型对复杂渗漏入口定位提供技术支持。

## 4 结 论

本文通过示踪剂运动刻画来训练 Transformer 模型进而识别渗漏入口的位置，并通过室内模型试验来验证方法可行性，从而研究堤坝渗漏入口的精准识别。得到以下三点结论。

(1) Transformer 模型在不同的迭代次数和数据采集时长学习训练中，随着迭代次数在不断增加，Transformer 模型的预测效果逐渐增强，迭代次数为 600 时预测效果达到最佳；在最优迭代次数下，改变数据长度研究 Transformer 模型对数据长度的依赖程度，模型在数据采集时长为 50 s 时，预测效果最佳。

(2) Transformer 模型在最优迭代次数和数据长度条件下预测结果的分析得出，Transformer 模型预测精度超过 95%，其中预测的入口大小和渗漏流量与真实值非常接近，位置的相对误差低于 5%。故 Transformer 模型能对壁面流速分布进行精准预测，从而得到渗漏入口的精准定位信息。

(3) 在室内模型试验中，通过将采集到的电导率数据转换为示踪剂浓度，并将其输入至 Transformer 模型，进而预测流速分布。基于预测的流速分布，模型能够准确定位渗漏入口的位置。与实际值对比结果表明，流速和渗漏入口坐标的预测平均相对误差均低于 10%，验证了 Transformer 模型在渗漏入口定位中的有效性与准确性。

## 参 考 文 献：

- [1] 李国英. 推动新阶段水利高质量发展全面提升国家水安全保障能力——写在 2022 年“世界水日”和“中国水周”之际[J]. 水利发展研究, 2022, 22(3): 1-2. (LI Guoying. Promoting the high-quality development of water conservancy in the new stage and comprehensively improve supporting capability of the national water security—Written on the occasion of World Water Day and China Water Week in 2022[J]. Water Resources Development Research, 2022, 22(3): 1-2. (in Chinese))
- [2] Yasuda S, Shimizu Y, Deguchi K. Investigation of the mechanism of the 2015 failure of a dike on Kinu River[J]. Soils and Foundations, 2016, 56(4): 581-592.
- [3] 张家荣, 刘建林. 中国尾矿库溃坝与泄露事故统计及成因分析 [J]. 中国钼业, 2019, 43 (04): 10-14. (ZHANG Jiarong, LIU Jianlin. The statistics and cause analysis of dam break and leakage in Chinese tailings pond[J]. China Molybdenum Industry, 2019, 43 (04): 10-14. (in Chinese))
- [4] 刘金鹏, 王志豪, 汤克轩, 等. 综合物探法在堤防渗漏检测中的应用 [J]. 河北水利电力学院学报, 2023, 33 (04): 1-7. (LIU Jinpeng, WANG Zhihao, TANG Kexuan, et al. Application of Comprehensive Geophysical Exploration Method in Leakage Detection of levee[J]. Journal of Hebei University of Water Resources and Electric Engineering, 2023, 33 (04): 1-7. (in Chinese))
- [5] Akdemir H, Bayindir C. Danger level ranking of possible dam failures in Turkey by grey relational analysis[C]. International Conference on Intelligent and Fuzzy Systems. Cham: Springer International Publishing, 2022: 237-243.
- [6] 陈强, 薛振兴. 我国不同地区大坝病险成因与防治措施研究[J]. 水利水电技术, 2021, 52(S2): 62-65. (CHEN Qiang, XUE Zhenxing. Research on the causes and prevention measures of dam diseases in different areas of China[J]. Water Resources and Hydropower Engineering, 2021, 52(S2): 62-65. (in Chinese))
- [7] 蔡跃波, 向衍, 盛金保, 孟颖. 重大水利工程大坝深水检测及突发事件监测预警与应急处置研究及应用[J]. 岩土工程学报, 2023, 45(3): 441-458. (CAI Yuebo, XIANG Yan, SHENG Jinbao, MENG Ying Deep-water detection, monitoring, early warning and treatment of emergencies of major water conservancy projects: a review[J]. Chinese Journal of Geotechnical Engineering, 2023, 45 (3): 441-458. (in Chinese))
- [8] 盛金保, 向衍, 杨德玮, 等. 水库大坝安全诊断与智慧管

- 理关键技术与应用[J]. 岩土工程学报, 2022, 44 (07): 1351-1366. (SHENG Jinbao, XIANG Yan, YANG Dewei, et al. Key technologies and applications of safety diagnosis and smartmanagement of reservoir dams[J]. Chinese Journal of Geotechnical Engineering, 2022, 44 (07): 1351-1366 (in Chinese))
- [9] 李雷, 蔡跃波, 盛金保. 中国大坝安全与风险管理的现状及其战略思考[J]. 岩土工程学报, 2008, (11): 1581-1587. (LI Lei, CAI Yuebo, SHENG Jinbao. Dam safety and risk management in China and its strategic consideration[J]. Chinese Journal of Geotechnical Engineering, 2008, (11): 1581-1587 (in Chinese))
- [10] Xu Y, Zhang L M, Jia J S. Diagnosis of embankment dam distresses using Bayesian networks. Part II. Diagnosis of a specific distressed dam[J]. Canadian geotechnical journal, 2011, 48(11): 1645-1657.
- [11] Teng S, Liu A, Ye X, et al. Review of intelligent detection and health assessment of underwater structures[J]. Engineering Structures, 2024, 308: 117958.
- [12] Hinton G E, Osindero S, Teh Y-W. A fast learning algorithm for deep belief nets[J]. Neural computation, 2006, 18(7): 1527-54.
- [13] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [14] Islam M R, Azam S, Shanmugam B, et al. Leak Detection and Localization in Underground Water Supply System Using Thermal Imaging and Geophone Signals Through Machine Learning[J]. Intelligent Systems with Applications, 2024: 200404.
- [15] Xiao F L, Hai L, Feng Z, et al. Deep learning - based nondestructive evaluation of reinforcement bars using ground - penetrating radar and electromagnetic induction data[J]. Computer - Aided Civil and Infrastructure Engineering, 2021, 37(14): 1834-1854.
- [16] Wei X, Ke H C, Ting L, et al. Efficient Underground Target Detection of Urban Roads in Ground-Penetrating Radar Images Based on Neural Networks[J]. Remote Sensing, 2023, 15(5): 1346.
- [17] 黄宏伟, 李庆桐. 基于深度学习的盾构隧道渗漏水病害图像识别[J]. 岩石力学与工程学报, 2017, 36(12): 2861-2871.
- (HUANG Hongwei, LI Qingtong. Image recognition for water leakage in shield tunnel based on deep learning[J]. Chinese Journal of Rock Mechanics and Engineering, 2017, 36(12): 2861-2871 (in Chinese))
- [18] 武建华, 梁利辉, 张喆, 等. 基于深度学习的变电站设备油液渗漏检测识别[J]. 广东电力, 2020, 33(11): 9-15. (WU Jianhua, LIANG Lihui, ZHANG Zhe, et al. Object detection of oil leakage in substation equipment based on deep learning[J]. Guangdong Electric Power, 2020, 33(11): 9-15. (in Chinese))
- [19] 陈前. 基于深度学习的隧道渗漏水特征识别算法研究[D]. 武汉: 华中科技大学, 2019. (CHEN Qian. Research on deep learning algorithm for feature recognition of tunnel leakage [D]. Wuhan: Huazhong University of Science and Technology, 2019. (in Chinese))
- [20] 翟俊海, 赵文秀, 王熙照, 等. 图像特征提取研究[J]. 河北大学学报(自然科学版), 2009, 29(1): 106-112. (ZHAI Junhai, ZHAO Wenxiu, WANG Xizhao, et al. Research on image feature extraction[J]. Journal of Hebei University (Natural Science Edition), 2009, 29(1): 106-112. (in Chinese))
- [21] Yan X, Enhua X, Shuangting L. Leakage diagnosis of water supply network by SVM[C]. 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE). IEEE, 2020: 94-97
- [22] Han K, Xiao A, Wu E, et al. Transformer in transformer[J]. Advances in Neural Information Processing Systems, 2021, 34(1): 15908-15919.
- [23] Vaswani A. Attention is all you need[J]. arxiv preprint arxiv:1706.03762, 2017.
- [24] 杨有帅. 基于 Transformer 的图像特征提取方法研究[D]. 四川: 电子科技大学, 2023. (YANG Youshuai. Research on image feature extraction method based on Transformer[D]. Sichuan: University of Electronic Science and Technology of China, 2023. (in Chinese))
- [25] 王兴浩. 基于贝叶斯优化的图神经网络架构搜索方法[D]. 吉林: 吉林大学, 2023. (WANG Xinghao. Graph neural architecture search method based on bayesian optimization [D]. Jilin: Jilin University, 2023. (in Chinese))