

DOI:10.20040/j.cnki.1000-7709.2025.20250246

基于VMD的供水管道漏损检测研究

何立新^{1a,2},管涌康^{1a,2},张 崢^{1b,2},程 楠^{1b,2},张宏洋^{1b,2},龙 岩^{1b,2}

(1. 河北工程大学 a. 能源与环境工程学院; b. 水利水电学院, 河北 邯郸 056038;

2. 河北省智慧水利重点实验室, 河北 邯郸 056038)

摘要: 供水管道漏损不仅会造成经济损失,还会带来安全隐患,对供水管道漏损的检测一直是行业研究的焦点。采用变分模态分解(VMD)方法对由主动关阀引起的水锤压力波动信号进行分析,通过提取模态的特征参数,运用支持向量机(SVM)分类模型对5种特征组合进行训练与测试,用于检测管道漏损。结果表明,VMD方法能够有效分离压力波动信号中的有用信号成分并减少噪声干扰,融合模态频率与能量比的SVM分类模型在试验管道与真实管网中准确率分别为96.12%、92.26%。该结果验证了利用VMD对压力波动分析能够有效识别管道漏损,降低检测成本。

关键词: 漏损检测;变分模态分解;关阀水锤;供水管道;支持向量机

中图分类号: TV672⁺.2

文献标志码: A

文章编号: 1000-7709(2025)12-0142-05

1 引言

在现代工业和日常生活中,管道系统广泛应用于供水、供油、供气等多个领域。管道的安全稳定运行至关重要,但管道漏损现象时常发生。特别是在给水工程中,管道漏损不仅会导致水资源浪费、能源损耗和环境污染,还可能引发灾难性后果,如爆炸、火灾等。因此,及时、准确地对供水管道漏损检测成为保障管道系统安全运行的关键环节。随着技术的发展,许多检测方法应运而生。ZHANG Z等^[1]通过分析管道漏损时产生的声信号,提取梅尔频率倒谱系数(MFCC)来识别漏损,但声信号受周围环境影响大,当外界噪声过强时会影响判别准确性;宋杰等^[2]基于支持向量机(SVM)对管道的流量和压力进行分析,实现了对管道漏损位置与水量的定位和预测;聂维^[3]采用负压波法产生的瞬变流分析对供水管道漏损进行检测,但负压波法是一种被动的检测方式,需要保证传感器时刻稳定工作。变分模态分解技术由于能够有效去除复杂信号中的噪声,因此被广泛应用于机械故障诊断、生物医学信号处理等领域^[4-5]。为此,本文基于变分模态分解方法,对由

主动关阀引起的压力波动进行分析,旨在提供一种更有效、更灵敏的供水管道漏损检测途径。

2 研究方法

2.1 变分模态分解

变分模态分解(VMD)是一种自适应信号处理方法,通过构造变分约束优化问题将复杂信号分解为若干窄带模态分量^[6],这一过程能有效避免各模态间的混淆,并确保每个模态的频率特性清晰可区分,从而具备良好的抗混叠能力。其核心思想是结合希尔伯特变换与频域优化,最小化各模态的带宽总和,同时确保分量叠加后重构原始信号,从而避免模态混叠。VMD的约束问题被定义为:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (1)$$

式中, $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 为对信号 f 分解后得到的 k 个模态分量; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为各模态分量的中心频率; ∂_t 为时间 t 的偏微分算

收稿日期: 2025-01-15, 修回日期: 2025-02-27

基金项目: 国家重点研发计划(2023YFC3209400)

作者简介: 何立新(1966-),男,博士、教授、博导,研究方向为智慧水务与水文水资源, E-mail: helixin@hebeu.edu.cn

通讯作者: 张崢(1981-),男,博士、副教授,研究方向为智慧水利, E-mail: zhangzheng@hebeu.edu.cn

子; $\delta(t)$ 为单位冲击函数; j 为虚数单位; $u_k(t)$ 为对应于每个模态的调幅调频信号。

针对公式的约束变分问题,同时引入拉格朗日算子 λ 和二次惩罚因子 α 使其变为非约束性变分问题。增广拉格朗日函数为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda, f(t) - \sum_k u_k(t) \rangle \quad (2)$$

通过交替方向乘子法(ADMM)在频域内迭代更新 u_k 、 ω_k 、 λ ,直至收敛至最优解。

2.2 模态能量比

模态能量比为不同模态对总信号能量的贡献。每个模态成分代表信号中的一部分能量,通过计算每个模态的能量占总信号能量的比例,可以评估每个模态在信号中的重要性。模态能量比 E_m 计算公式为:

$$E_m = \frac{\sum_{i=1}^N |\text{IMF}_n[i]|^2}{\left(\sum_{i=1}^N |f[i]|^2 \right)} \quad (3)$$

式中, $\text{IMF}_n[i]$ 为第 n 个模态的第 i 个样本值; $f[i]$ 为原始信号的第 i 个样本值; N 为信号的总样本数。

通过计算每个模态能量占总能量的比例,可以评估模态的重要性。模态能量比高的模态通常对信号特征的特征更为显著。

2.3 支持向量机

支持向量机(SVM)是一种基于统计学习理论的监督式机器学习算法,旨在通过构建最大间隔超平面实现数据分类^[7]。SVM擅长处理小样本、高维和非线性问题。超平面的定义为:

$$f(x) = \alpha + \beta^T x \quad (4)$$

式中, α 为偏置; β 为权重向量。

对于非线性可分数据,SVM通过核函数将低维特征映射到高维空间,隐式地实现线性划分。在高维空间中,SVM通过最大化间隔来确保分类的最优性。分类性能的好坏依赖于正则化 C 和核函数的参数。因此,本文采用网格搜索与交叉验证相结合的方式,优化这些参数组合,从而提升模型的泛化能力。

2.4 模型性能评估

管道漏损的检测为一个二分类问题,根据模型的预测结果可分为4类^[8]:①正确判断出管道漏损为真阳性(T_{TP});②正确判断出模型未漏损为真阴性(T_{TN});③错误判断出管道漏损为假阳性(F_{FP});④错误判断出管道未漏损为假阴性

(F_{FN})。采用准确率($A_{Accuracy}$)和特异性($S_{Specificity}$)及F1分数(S_{F1})对模型进行评估,其公式为:

$$A_{Accuracy} = \frac{T_{TP} + T_{TN}}{T_{TP} + T_{TN} + F_{FP} + F_{FN}} \times 100\% \quad (5)$$

$$S_{Specificity} = [T_{TN} / (T_{TN} + F_{FP})] \times 100\% \quad (6)$$

$$S_{F1} = \frac{2P_{Precision}R_{Recall}}{P_{Precision} + R_{Recall}} \times 100\% \quad (7)$$

式中, $P_{Precision}$ 、 R_{Recall} 分别为精确率和召回率,其计算公式为:

$$P_{Precision} = [T_{TP} / (T_{TP} + F_{FP})] \times 100\% \quad (8)$$

$$R_{Recall} = T_{TP} / (T_{TP} + F_{FN}) \quad (9)$$

由式(8)、(9)可知,精确率和召回率是相互制约的关系,F1分数为二者的调和平均值,能够综合精确率和召回率的表现。F1分数的范围为0~1,值越接近1,表明模型性能越佳。

2.5 试验装置

如图1所示,试验管道系统由2台水泵供水,其中水泵A为工频泵,频率为30 Hz,水泵B为最大频率50 Hz的变频泵。主干管道为直径250 mm,壁厚2.5 mm的不锈钢管道。漏损位置通过在主干管道上开设直径20 mm的模拟漏孔进行复现。在主干管道末端设置压力传感器,采样频率为1 000 Hz。在管道末端连接直径为50 mm的管道,并安装电磁阀和手动阀,通过这两种阀门的关闭可以激发水锤波。系统中主干管道的长度为48.65 m,漏损点1距离传感器28.69 m,漏损点2距离传感器14.72 m。




图1 管道漏损检测系统布置

Fig. 1 Layout of pipeline leakage detection system

3 基于VMD的供水管道漏损检测研究

3.1 整体技术路线

研究的技术路线为:①通过管道系统中的压力传感器获得管道漏损与未漏损时的水锤压力波动数据;②对数据进行预处理后,采用VMD方法对数据进行分解,获得不同模态分量的最大频率及对应的模态能量比;③对分解结果进行分析,选取有效模态分量;④对有效模态分量依据分量的频率及能量比分成5组不同的特征组合,采用SVM算法进行训练和测试。

3.2 数据采集

为获得不同作用水头下水锤波的压力信号,

试验中仅开启变频泵。在开始采集数据之前,需先对管道系统进行充水排气,当管道排气阀无水喷溅后开始试验。变频泵频率从 36 Hz 开始,每次以 2 Hz 的增量逐步增加至 50 Hz,针对漏损位置不同,设置工况 1~3,分别为无漏损、位置 1 漏损、位置 2 漏损,在不同工况下关闭电磁阀以激发水锤波。

在管道系统末端由采样频率为 1 000 Hz 的压力传感器采集压力波动信号,对采集的压力信号进行预处理(包括去除直流分量消除信号中的直流偏移),得到可用于分析的标准化压力信号数据。

3.3 VMD 分析及有效模态分量选取

VMD 分解后的模态特征见表 1。对模态频率及能量比的分析结果表明,低频模态(如 IMF1、IMF2)波形平稳能反映水锤波的基本特征形态,高频模态(如 IMF3 及以上)能量占比低且呈现噪声特性。

表 1 三种工况条件下分解后的模态特征

Tab. 1 Modal characteristics after decomposition under three working conditions

水泵频率 / Hz	模态分量	工况 1		工况 2		工况 3	
		最大频率 / Hz	模态能量比	最大频率 / Hz	模态能量比	最大频率 / Hz	模态能量比
36	IMF1	1.6	9.61×10^{-1}	0.3	9.32×10^{-1}	0.3	9.36×10^{-1}
	IMF2	9	1.40×10^{-2}	4.4	5.65×10^{-2}	4.6	4.71×10^{-2}
	IMF3	107.2	7.07×10^{-4}	107.1	7.59×10^{-5}	107	4.58×10^{-4}
38	IMF1	1.9	9.57×10^{-1}	0.3	9.40×10^{-1}	0.3	9.11×10^{-1}
	IMF2	10.4	1.80×10^{-2}	3.8	4.60×10^{-2}	4.6	6.98×10^{-2}
	IMF3	94.2	1.09×10^{-4}	78.2	5.00×10^{-5}	112.9	1.95×10^{-4}
40	IMF1	1.9	9.65×10^{-1}	0.4	9.44×10^{-1}	0.3	9.45×10^{-1}
	IMF2	9.3	1.32×10^{-2}	4.9	4.36×10^{-2}	5.1	4.00×10^{-2}
	IMF3	118.9	1.05×10^{-4}	118.8	2.78×10^{-4}	118.8	3.81×10^{-4}
42	IMF1	1.9	9.43×10^{-1}	0.4	9.28×10^{-1}	0.4	9.15×10^{-1}
	IMF2	9.3	2.89×10^{-2}	4.9	6.14×10^{-2}	5.1	5.80×10^{-2}
	IMF3	124.6	8.88×10^{-5}	20.8	2.30×10^{-4}	6.7	4.00×10^{-3}
	IMF4			159.2	4.74×10^{-6}	20.8	1.12×10^{-4}
44	IMF1	2.0	9.38×10^{-1}	0.4	9.18×10^{-1}	0.4	9.38×10^{-1}
	IMF2	10.3	2.98×10^{-2}	5.6	6.96×10^{-2}	5.4	4.68×10^{-2}
	IMF3	130.6	4.62×10^{-5}	21.8	2.66×10^{-4}	21.7	2.67×10^{-4}
	IMF4			33.3	5.34×10^{-5}	160.6	5.02×10^{-6}
	IMF5			158.6	6.05×10^{-6}		
46	IMF1	1.9	7.26×10^{-1}	0.4	9.29×10^{-1}	0.4	9.26×10^{-1}
	IMF2	11.5	1.56×10^{-2}	5.5	5.94×10^{-2}	5.7	3.80×10^{-2}
	IMF3	17.2	1.22×10^{-3}	321.9	1.11×10^{-6}	6.9	9.46×10^{-3}
	IMF4	86.6	8.07×10^{-6}			22.7	1.74×10^{-4}
	IMF5					45.5	2.34×10^{-5}
	IMF6					159	3.67×10^{-6}
48	IMF1	2.4	9.20×10^{-1}	0.5	9.47×10^{-1}	0.5	9.46×10^{-1}
	IMF2	11.1	3.64×10^{-2}	5.4	4.31×10^{-2}	5.8	4.07×10^{-2}
	IMF3	314.6	1.04×10^{-6}	297	8.49×10^{-7}	23.7	9.78×10^{-5}
	IMF4					142.2	3.02×10^{-6}
50	IMF1	2.3	6.84×10^{-1}	0.5	9.54×10^{-1}	0.5	9.53×10^{-1}
	IMF2	11.5	2.14×10^{-2}	5.8	3.62×10^{-2}	6.1	2.77×10^{-2}
	IMF3	22.8	4.60×10^{-3}	24.7	1.69×10^{-4}	7.7	2.52×10^{-3}
	IMF4	298.4	3.62×10^{-7}	148	2.23×10^{-6}	95.5	4.31×10^{-6}

在能量分布特征上具体表现为在 36~50 Hz 频率条件下,低频模态的模态能量比均高于高频模态。以 36 Hz 条件下 3 个不同工况为例,低频模态 IMF1 模态能量比分别为 9.61×10^{-1} 、 9.32×10^{-1} 、 9.36×10^{-1} , IMF2 模态能量比分别为 $1.40 \times$

10^{-2} 、 5.65×10^{-2} 、 4.71×10^{-2} , 而高频模态 IMF3 能量比分别为 7.07×10^{-4} 、 7.59×10^{-5} 、 4.58×10^{-4} 。表明该频段的低频模态在信号中起主导作用。

对时频特性进行分析表明,高频模态时域波动性强,频域能量分散,与噪声特性一致,表现出较强的噪声特性,而低频模态则具有较平滑的波形,说明低频模态在压力信号分析中占重要地位,能较好地反映信号的基本特征,适用于提取水锤信号的基本轮廓。以 50 Hz 下工况 2 分解的模态分量(图 2)为例,低频模态的频谱特征较为平稳,且模态能量比表现出较强的主导作用,而高频模态频谱特征不稳定,同时分析模态能量比可知对压力波动的表征较弱。




图 2 50 Hz 工况 2 分解的模态分量

Fig. 2 Modal components decomposed under 50 Hz condition 2

综上所述,低频模态可表征压力波动的核心特征,而高频模态因噪声干扰需在特征提取中予以剔除,故选取 IMF1、IMF2 作为有效分量进行分析。

3.4 对比分析

基于不同频率和漏损工况下压力信号变分模态分解后的结果,将信号有效模态分量的频率分解为模态能量比范围在 10^{-2} 、 10^{-1} 量级的两类。在变频泵 36~50 Hz 频段,模态能量比在 10^{-1} 量级的模态信号频率在未漏损时处于 1.6~2.4 Hz 范围,而漏损时频率则下降至 0.3~0.5 Hz。同时,模态能量比为 10^{-2} 量级的模态信号频率未漏损时处于 8.8~11.5 Hz 范围内,而漏损时下降至 3.8~5.8 Hz。

如图 3 所示,通过对这两个不同能量量级内的频率变化进行分析,可以清晰地观察到漏损与无漏损工况下的显著差异。与管道无漏损时相比,漏损工况下两个模态能量比范围内的模态频率均有明显降低。在变频泵 36~50 Hz 频段内,模态能量比在 10^{-1} 量级的模态频率下降幅度为 78.9%~84.2%,在 10^{-2} 量级最大频率下降幅度




图 3 模态频率变化对比

Fig. 3 Comparison of modal frequency changes

为 45.2%~63.5%。

3.5 模型训练

支持向量机是一种基于小样本训练的识别方法,不同神经网络方法需要大量样本做训练测试,分类采用“一对其余”的策略即将工况 2、3 归于漏损类,单独将工况 1 作为未漏损类。采用 SVM 分类算法验证不同特征组合对分类性能的影响,设计 5 组训练样本进行对比分析:A 组采用分解的所有模态频率为训练样本、B 组采用模态能量比为 10^{-1} 量级的模态频率为训练样本、C 组采用模态能量比为 10^{-2} 量级模态频率为训练样本、D 组同时采用 10^{-2} 、 10^{-1} 量级的模态频率为训练样本;E 组以 10^{-2} 、 10^{-1} 量级的模态频率以及能量比作为训练样本。

3.6 结果与分析

3.6.1 模型测试

将采集的 148 组压力波动数据按 7 : 3 划分为训练集与测试集,并对 5 种训练样本的模型性能进行对比测试。结果如表 2 所示,E 组(模态频率+能量比)在准确率、特异性和 F1 分数上均表现最佳,分别为 96.12%、89.47%、97.01%,显著优于其他组合。

表 2 模型测试性能对比

Tab. 2 Model test performance comparison

性能指标	训练样本				
	A	B	C	D	E
准确率/%	53.40	83.50	66.99	86.41	96.12
特异性/%	37.04	71.79	65.63	81.25	89.47
F1 分数/%	59.32	87.22	80.00	90.00	97.01

在特征组合对分类性能的影响方面,A 组(所有模态频率)在没有选取有效模态分量的情况下

准确率仅 53.40%,表明通过选取有效分量可有效剔除干扰信息,提升模型性能。B、C 组均采用单一特征,但 B 组(主导模态频率)与 C 组(次要模态频率)性能差异明显,其中 B 组的准确率高出 C 组 16.51%,证明主导模态频率对漏损的敏感度更高。D 组(主次模态频率组合)的性能仅次于 E 组,准确率为 86.41%,特异性为 81.25%,F1 分数为 90.00%,与 B、C 组对比,验证了单一特征的局限性。同时与 E 组相比,准确率低 9.71%、特异性低 8.22%、F1 分数低 7.01%,性能差异明显,证明了融合模态频率和能量比可有效提升模型性能。

关阀引起的瞬态压力波动信号具有短时冲击特性,传统方法难以分离瞬态成分,VMD 通过频域优化约束将该信号自适应分解为窄带模态分量,可有效解决模态混叠问题,分解后的各分量频谱边界清晰,为特征提取提供了高鲁棒性框架,结合 SVM 的多模态特征融合策略,E 组模型在测试集上对管道漏损检测准确率为 96.12%,在实际管网中准确率仅下降 3.26%,证明了 VMD 技术在复杂场景的适用性。

3.6.2 实际管网验证

为验证模型的鲁棒性,在华北地区真实供水管网中改变泵的频率和漏损工况,采集到 168 条压力波动数据,将采集到的压力信号进行变分模态分解,提取有效模态分量在新的测试集上对 4 种模型进行对比,验证结果见表 3。

表 3 模型在新测试集中性能对比

Tab. 3 Performance comparison of model in new test set

性能指标	训练样本				
	A	B	C	D	E
准确率/%	55.36	74.40	67.86	82.12	92.26
特异性/%	37.97	58.44	51.22	68.57	84.13
F1 分数/%	62.69	78.82	72.73	85.71	94.01

相对于模型测试阶段由于实际管网中环境不同存在更多干扰,导致 B、C、D、E 性能均下降,其中 E 组仍保持最优性能,验证了融合模态频率与能量比特征的适用性。通过分析特异性指标发现不同组合下其值均低于准确率和 F1 分数,表明对管道未漏损的检测性能较差,影响了检测的准确率。

4 结论

本文采用 VMD 对供水管道中关阀引起的压力波动进行分解,采用 SVM 对不同特征组合训练与测试。结果表明,结合模态能量比和时频分

析选取 VMD 分解后的有效分量,可显著提升模型性能,结合模态频率与能量比为管道漏损检测提供了重要的信号特征,显著提高了漏损检测的准确性,未来研究可扩展至漏损位置定位与漏损量的分析。

参考文献:

[1] ZHANG Z Y, XU C H, XIE J, et al. MFCC-LSTM framework for leak detection and leak size identification in gas-liquid two-phase flow pipelines based on acoustic emission[J]. *Measurement*, 2023, 219: 113238.

[2] 宋杰, 吕谋, 郝晨西, 等. 基于 PSO-SVM 模型的供水管网漏损诊断[J]. *水电能源科学*, 2020, 38(7): 122-125.

[3] 聂维. 基于负压波的供水管道泄漏检测与漏点定位方法研究[D]. 成都: 西华大学, 2022.

[4] LIU H B, XU Q Z, HAN X L, et al. Attention on

the key modes: Machinery fault diagnosis transformers through variational mode decomposition [J]. *Knowledge-based systems*, 2024, 289: 111479.

[5] YAMADA T, OBATA Y, SUDO K, et al. Changes in EEG frequency characteristics during sevoflurane general anesthesia: Feature extraction by variational mode decomposition [J]. *Journal of clinical monitoring and computing*, 2023, 37(5): 1179-1192.

[6] 唐泽娴, 林建辉, 丁建明, 等. 万向轴动不平衡检测的自适应变分模态分解方法 [J]. *机械设计与制造*, 2022(2): 132-134.

[7] 曾广栋, 魏学锋, 何林, 等. 基于音频特征的水车室工作状态异常检测 [J]. *水电能源科学*, 2024, 42(8): 168-172.

[8] 何立新, 张宏洋, 张峥, 等. 基于梅尔频率倒谱系数特征识别供水管网漏损的机器学习模型比较研究 [J]. *给水排水*, 2024, 50(8): 137-143.

Research on Leakage Detection of Water Supply Pipeline Based on VMD

HE Li-xin^{1a,2}, GUAN Yong-kang^{1a,2}, ZHANG Zheng^{1b,2}, CHENG Nan^{1b,2},
ZHANG Hong-yang^{1b,2}, LONG Yan^{1b,2}

(1a. School of Energy and Environmental Engineering; 1b. School of Water Conservancy and Hydroelectric Power, Hebei University of Engineering, Handan 056038, China; 2. Hebei Key Laboratory of Intelligent Water Conservancy, Handan 056038, China)

Abstract: Water supply pipeline leakage will not only cause economic losses, but also bring security risks. The detection of water supply pipeline leakage has always been the focus of industry research. The variational mode decomposition (VMD) method was used to analyze the water hammer pressure fluctuation signal caused by active valve closing. By extracting the characteristic parameters of the mode, the support vector machine (SVM) classification model was used to train and test the five feature combinations for detecting pipeline leakage. The results show that the VMD method can effectively separate the useful signal components in the pressure fluctuation signal and reduce the noise interference. The accuracy of the SVM classification model combining modal frequency and energy ratio in the experimental pipeline and the real pipeline network is 96.12% and 92.26%, respectively. The results verify that the analysis of pressure fluctuation by VMD can effectively identify pipeline leakage and reduce detection cost.

Key words: leakage detection; variational mode decomposition; closure valve water hammer; water supply pipeline; support vector machine

(上接第 121 页)

[6] JIANG X Y, LU Q R, CHEN X P, et al. Numerical analysis of deep foundation pit excavation process [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 719(3): 032051.

[7] 霍子豪, 张仕林, 胡卸文, 等. 基于固液耦合的滑坡碎屑流侵蚀流化机理研究 [J]. *水文地质工程地质*, 2025, 52(2): 138-149.

[8] WANG J, LI H F, WU S Z, et al. Numerical simulation and field test of the interaction between existing station and enclosure in open excavation and adding stories construction [J]. *Applied sciences*, 2022, 12(19): 9563.

[9] ZHANG W G, HAN L, GU X, et al. Tunneling and deep excavations in spatially variable soil and rock masses: A short review [J]. *Underground space*, 2022, 7(3): 380-407.

Numerical Investigation of Deformation in Shaft Construction Using Mechanical Approach

LU Shao-zhuang, CHEN Ying-jie, RONG Ming

(College of Hydraulic and Civil Engineering, Xinjiang Agricultural University, Urumqi 830052, China)

Abstract: To address the difficulty in predicting shaft settlement during mechanical excavation-affected by multiple factors such as soil excavation, groundwater level variation, and stratum disturbance, taking a shaft based on mechanical methods as an example, this study proposes a fluid-solid coupling simulation method based on finite element analysis. The settlement generated by mechanical shaft construction was simulated and further compared with an excavation case study. The results show that the maximum vertical displacement occurs at the outer edge of the ring beam, located at the interface between the triaxial mixing pile reinforcement zone and the surrounding soil, with a magnitude of 6.9 mm. The maximum horizontal displacement of the deep soil layer appears at a depth of 17 m, shifting 11.66 mm toward the shaft interior. The simulated data showed consistent variation trends with the monitoring data, with a maximum displacement deviation of 8.5%. This study clarifies the detailed application procedure of mechanical-method shaft settlement simulation and provides a new approach for calculating settlement behavior during mechanical shaft construction.

Key words: mechanical method; shaft; deformation; numerical analysis