

郭琦, 任植元, 汤正举, 等. 基于三阶段动态分析的供水管网 DMA 漏损识别方法[J]. 净水技术, 2026, 45(9): 73-81.

Guo Q, Ren Z Y, Tang Z J, et al. Leakage identification method in DMA for water supply pipeline networks based on three-stage dynamic analysis[J].

Water Purification Technology, 2026, 45(9): 73-81.

基于三阶段动态分析的供水管网 DMA 漏损识别方法

郭琦¹, 任植元², 汤正举³, 苗大勇³, 陈博³, 郭冠呈^{1,*}

(1. 清华大学环境学院, 北京 100084; 2. 内蒙古科技大学能源与环境学院, 内蒙古包头 014010; 3. 河南力科管线探测技术有限公司, 河南郑州 450000)

摘要 【目的】独立计量分区(DMA)管理是供水管网漏损控制的重要方法之一,其核心在于准确判断漏损发生区域。然而,现有的 DMA 漏损识别方法普遍存在精度低、误报率高等问题,难以满足复杂动态管网管理的需求。【方法】为解决这一问题,本文提出了 1 种基于三阶段动态分析的 DMA 漏损识别方法,以提升识别的准确性和可靠性。第一阶段采用滑动窗口技术,通过捕捉短期流量变化特征,增强对动态流量数据的敏感性,并有效过滤随机噪声干扰;第二阶段构建基于历史数据的流量预测模型,对比实际流量与预测流量之间的残差,精准捕捉流量异常变化特征;第三阶段进一步分析残差异常变化的时间特性,剔除由用户正常波动引起的误差干扰,重点识别异常泄漏信号。在泄漏试验中,选择了郑州 2 个不同规模的 DMA 小区进行测试和验证。【结果】该方法的准报率约为 81.84%,误报率约为 3.87%,识别效果优于传统方法,且在凌晨低流量时段的识别效果显著优于白天高流量时段。【结论】该方法能够更好地捕捉由于管网泄漏导致的流量异常波动,在实际管网中展现出较好的应用前景。本文为供水企业提供了 1 种高效实用的 DMA 漏损识别解决方案,既提高了识别的精准性和可靠性,又推动了漏损控制从传统经验管理向智能化、精准化转型,具有重要的理论和应用价值。

关键词 供水管网; 独立计量分区; 漏损识别; 滑动窗口; 流量预测; 残差分析

中图分类号: TU991 **文献标志码:** A **文章编号:** 1009-0177(2026)09-0073-09

DOI: 10.15890/j.cnki.jsjs.2026.09.008

Leakage Identification Method in DMA for Water Supply Pipeline Networks Based on Three-Stage Dynamic Analysis

Guo Qi¹, Ren Zhiyuan², Tang Zhengju³, Miao Dayong³, Chen Bo³, Guo Guancheng^{1,*}

(1. School of Environment, Tsinghua University, Beijing 100084, China;

2. School of Energy and Environment, Inner Mongolia University of Science and Technology, Baotou 014010, China;

3. Henan Leak Pipeline Detection Technology Co., Ltd., Zhengzhou 450000, China)

Abstract [Objective] District metered area (DMA) management is one of the key methods for controlling leakage in supply pipelines, with its core focusing on accurate identification leakage areas. However, existing DMA leakage detection method generally suffer from low accuracy and high false alarm rates, making it difficult to meet the needs of managing complex and dynamic pipeline networks. [Methods] To address this issue, this paper proposes a DMA leakage identification method based on a three-stage dynamic analysis to improve the accuracy and reliability of identification. The first stage used a sliding window technique to capture short-term flow variation characteristics, enhancing sensitivity to dynamic flow data and effectively filtering out random noise interference. The second stage constructed a flow prediction model based on historical data, comparing the residuals between the actual flow and predicted flow to accurately capture abnormal flow variation characteristics. The third stage further analyzed the time characteristics of the residual anomalies, eliminating errors caused by normal fluctuations from users, and focused on identifying abnormal leakage signals. In the leakage tests, two DMA areas of different scales in Zhengzhou were selected for testing and verification.

[收稿日期] 2024-12-17

[基金项目] 国家重点研发计划(2023YFC3208103);清华大学“水木学者”计划(2023SM021)

[作者简介] 郭琦(1995—),男,大学本科,研究方向为供水管网漏损控制,E-mail: guoqi@mail.tsinghua.edu.cn。

[通信作者] 郭冠呈(1992—),男,博士研究生,研究方向为供水管网漏损控制,E-mail: ggc@mail.tsinghua.edu.cn。

[**Results**] The proposed method achieved a true positive rate of approximately 81.84% and a false positive rate of about 3.87%. Its performance outperformed traditional method, with particularly notable improvements in detection accuracy during low-flow periods at night compared to high-flow periods during the day. [**Conclusion**] This method is able to better capture abnormal flow fluctuations caused by pipeline leaks, demonstrating promising application prospects in real-world water supply networks. This paper provides water supply companies with an efficient and practical DMA leakage detection solution, which not only improves the accuracy and reliability of detection but also promotes the transformation of leakage control from traditional experience-based management to intelligent and precise management. It holds significant theoretical and practical value.

Keywords water supply pipeline network; district metered area (DMA); leakage identification; sliding window; flow prediction; residual analysis

随着全球水资源危机的加剧和城市化进程的推进,城市供水管网的漏损问题已成为制约水资源可持续利用的重要挑战。据统计^[1-2],全球供水管网的漏损率普遍较高,部分城市甚至达到 30% 以上。这不仅浪费了宝贵的水资源,还造成了经济损失,甚至可能引发次生灾害。如何准确识别管道漏损事件,降低管网漏损率,已成为供水行业的核心问题。

为了提升供水管网漏损控制效率,独立计量分区(DMA)管理模式得到了广泛应用。通过对区域水量进行精确监控,采用水量平衡分析、夜间最小流量分析、全天流量分析等方法判断 DMA 漏损情况^[3],大大缩小了管线巡检范围。然而,由于流量数据的复杂性和动态性,传统基于经验和物理建模的检测方法在复杂环境下往往难以高效工作,漏损检测的准确性和时效性面临挑战^[4]。

近年来,基于数据驱动的方法为 DMA 漏损识别提供了新思路,按照方法原理可将其分为 3 类:统计分析法、直接分类法和预测-分类两阶段法^[5]。统计分析法通过计算一段时间内流量数据的统计特征(如均值、方差等),当超过设定阈值时就判断为漏损,该方法简单快速,但准确率较低^[6];直接分类法将漏损识别视为一个二分类问题,利用随机森林、人工神经网络(ANN)等模型对流量数据直接进行分类(是否漏损),该方法受限于漏损标签样本量较少,识别效果尚不理想^[7];预测-分类两阶段法是目前较为主流的 DMA 漏损识别方法,通过对比分析流量预测值和真实值的残差来判断是否发生了漏损^[8]。国内外研究者^[9-12]使用了多种机器学习模型和技术来实现预测和分类,并取得了一定效果,但是这些方法在实际管网中的应用效果仍有待进一步提升。如何提高模型适用性和鲁棒性,以更好地满足复杂管网条件下的漏损识别需求,仍是当前研究

需要解决的关键问题。

综上所述,本文结合滑动窗口、流量预测和残差分析技术,提出了一种基于三阶段动态分析的 DMA 漏损识别方法。第一阶段通过滑动窗口技术捕捉短期流量变化特征,确保对动态数据的敏感性;第二阶段利用流量预测模型,通过学习历史流量数据的趋势和规律,生成预测流量值;第三阶段基于残差分析,计算实际流量值与预测值之间的差异,精准识别异常变化,同时有效剔除正常波动干扰。该方法具备实时性强、精度高、成本低等显著优势,为供水企业提供了一种高效、实用的漏损识别解决方案。

1 研究方法

1.1 方法框架

本文提出的 DMA 漏损识别方法分为 3 个阶段,如图 1 所示。第一阶段通过滑动窗口模型监测每个 DMA 流量数据的波动情况,当检测到波动异常时,自动进入第二阶段,构建该 DMA 的流量预测模型,计算流量预测值和真实值的残差。接着进入第三阶段,采用聚类方法分析残差分布情况,最终得出识别结果。如果第一阶段的滑动窗口模型判断 DMA 流量数据波动正常时,则不会进入第二阶段和第三阶段。

1.2 滑动窗口法

滑动窗口是 1 种有效的时间序列分割方法,广泛应用于时间序列数据的分析与建模中^[13]。在流量数据的异常检测中,滑动窗口可以将原始的时间序列划分为固定长度的连续时间段,为后续的分析提供结构化的样本数据。本文提出在第一阶段采用滑动窗口法初步判断流量数据是否发生异常波动,计算简单高效,适用于判断流量突变的工况。通过捕捉窗口范围内的流量变化特征,增强对动态流量数据的敏感性,有效过滤随机噪声的干扰。

本文将流量数据划分为时间序列和时序序列。




图1 DMA漏损识别方法框架

Fig. 1 Framework of DMA Leakage Identification Method

时间序列是指某1时刻及其前1段连续时间内的流量数据按时间顺序排列而成的序列；时序序列是指每日相同时刻的流量数据按时间顺序排列而成的序列，其数据间隔为1 d。对于流量的时间序列，本文提取 t 时刻及其前 m 个时刻的流量数据作为滑动窗口，即 $[Q_{t-m}, \dots, Q_t]$ ，对窗口内的序列做一阶差分，即 $[Q_{t-m+1} - Q_{t-m}, \dots, Q_t - Q_{t-1}]$ ，然后计算差分后序列的均值 μ_1 、方差 σ_1 、变化幅度 ε_1 ，如式(1)~式(3)。对于流量的时序序列，本文提取 t 时刻及其前 T 天相同时刻的流量数据作为滑动窗口，时间间隔为1 d，即 $[Q_{t-T}, \dots, Q_t]$ ，计算窗口内序列的均值 μ_2 、方差 σ_2 、变异系数 ρ_2 ，如式(4)~式(6)。比较相邻滑动窗口统计特征的变化情况，如果特征值的变化率超过设定阈值，就判断为异常点。

$$\mu_1 = \sum_{n=1}^m (Q_{t-n+1} - Q_{t-n}) \quad (1)$$

$$\sigma_1 = \frac{1}{m} \sum_{n=1}^m (Q_{t-n+1} - Q_{t-n} - \mu_1)^2 \quad (2)$$

$$\varepsilon_1 = \left| \max_{n=1 \sim m} (Q_{t-n+1} - Q_{t-n}) - \min_{n=1 \sim m} (Q_{t-n+1} - Q_{t-n}) \right| \quad (3)$$

$$\mu_2 = \sum_{n=1}^{d+1} (Q_{t-n+1}) \quad (4)$$

$$\sigma_2 = \frac{1}{d} \sum_{n=1}^{d+1} (Q_{t-n+1} - \mu_2)^2 \quad (5)$$

$$\rho_2 = \sqrt{\sigma_2} / \mu_2 \quad (6)$$

其中： Q_t —— t 时刻的流量数据， m^3/h ；
 μ_1 ——流量数据时间序列一阶差分后的均值， m^3/h ；
 σ_1 ——流量数据时间序列的方差；
 ε_1 ——流量数据时间序列的变化幅度， m^3/h ；
 μ_2 ——流量数据时序序列的均值， m^3/h ；

σ_2 ——流量数据时序序列的方差；

ρ_2 ——流量数据时序序列的变异系数。

1.3 流量预测法

长短时记忆网络(LSTM)是1种特殊的递归神经网络，广泛应用于时间序列数据的预测、自然语言处理、语音识别等领域，能够解决传统循环神经网络在学习长时间依赖关系时的不足。通过引入门控机制，LSTM有效缓解了梯度消失和梯度爆炸问题，在时间序列数据的处理和预测中展现出明显优势^[14]。本文提出在第二阶段采用流量预测法，利用LSTM搭建高精度的DMA流量预测模型，计算流量预测值与真实值的残差，为第三阶段的残差分析法奠定基础。

DMA流量预测模型的结构如图2所示，将流量数据的时间序列、时序序列以及环境信息作为模型的输入特征，环境信息包括天气、温度、每天时间段(依次分为凌晨、早高峰、中午、晚高峰4个时间段)、工作日和节假日。LSTM网络层对输入特征进行非线性变换，产生对过去流量的记忆状态，并建立不同时间段流量数据之间的依赖关系；然后按张量串联的方式连接成1个合并层，整合不同时间段的流量信息；之后串联多个全连接层进一步对特征进行不同程度的缩放和变换，提高模型处理非线性数据的能力；最后连接1个输出层，输出下一时刻的流量预测值。

1.4 残差分析法

本文提出在第三阶段采用残差分析法，利用 K 均值(K -Means)聚类方法分析流量预测值与真实值之间的残差变化规律，从而识别离群点并标记异常。这些异常点可能由设备故障、漏损事件或用户行为的突变引起。 K -Means方法基于聚类思想，将流量残差数据按照距离相似性分为若干组，通常主要聚




图 2 流量预测模型结构

Fig. 2 Structure of Flow Prediction Model

类中心(簇)包含正常点,而远离簇中心的点则被标记为离群点,从而识别异常^[15]。

本文提取 t 时刻及其前 1 段时间对应时刻的流量残差组成特征向量,然后将 t 时刻的流量残差依次减去特征向量中其他时刻的流量残差,从而得到 1 个关于 t 时刻流量残差变化率特征序列,将该序列的均值、方差、最大值和最小值作为 K-Means 模型的输入特征。如果连续 1 段时间内的流量残差都被识别为异常点,则判断 DMA 发生了漏损。

1.5 评价指标

本文选择平均绝对百分比误差 (MAPE) 作为预测模型的评价指标,MAPE 越低,模型效果越好^[8],如式(7)。选择准确率 (TPR) 和误报率 (FPR) 作为漏损识别模型的评价指标,TPR 越高,FPR 越低,模型效果越好。TPR 能够反映模型对泄漏样本的识别效果,FPR 能够反映模型对正常样本的识别效果,如式(8)~式(9)。

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (7)$$

$$T_{PR} = \frac{T_P}{T_P + F_N} \quad (8)$$

$$F_{PR} = \frac{F_P}{F_P + T_N} \quad (9)$$

其中: y_i ——真实流量值, m^3/h ;

$\hat{y}_i$ ——预测流量值, m^3/h ;

n ——样本总数;

T_P ——模型正确识别的泄漏样本数;

F_N ——模型错误识别的泄漏样本数;

F_P ——模型正确识别的正常样本数;

T_N ——模型错误识别的正常样本数。

2 案例分析

2.1 泄漏试验

选取郑州市 2 个不同规模的 DMA 小区开展泄漏试验,小区的用户主要为居民。试验小区一的用户规模 2 120 户,全年日均用水量约为 750 m^3 ;试验小区二的用户规模 484 户,全年日均用水量约为 150 m^3 。通过开关消防栓模拟实际泄漏场景,在不同时间段和不同泄漏流量下开展试验,远传流量计会记录试验过程中的流量数据波动情况,数据采集间隔为 5 min,如表 1 所示。

表 1 泄漏试验工况

Tab. 1 Working Conditions of Leakage Experiment

DMA 名称	试验日期	放水时间	泄漏流量/ ($\text{m}^3 \cdot \text{h}^{-1}$)
试验小区一	2024 年 8 月 9 日	21:30—22:15	2.489
		22:22—22:52	4.311
		22:55—23:33	1.750
	2024 年 8 月 10 日	2:27—3:00	1.796
		3:01—3:33	3.379
		3:36—4:10	4.731
试验小区二	2024 年 8 月 8 日	16:42—17:13	2.267
		17:14—17:41	7.390
		17:42—18:10	1.635
	2024 年 8 月 9 日	2:52—3:22	1.901
		3:23—3:53	3.594
		3:55—4:25	12.018

图3显示了2个试验小区的流量变化曲线,可以明显看出DMA流量变化的周期性和趋势性,流量变化规律受DMA用户规模和用水行为习惯等因

素的影响。试验小区一的用户规模较大,流量数据波动相对较小,而试验小区二的用户规模较小,流量数据波动则相对较大。




图3 试验小区流量变化曲线

Fig. 3 Flow Variation Curve of Experiment Area

为了保证数据的连续性,本文采用数据波动较小的时序序列对极端异常值和长期不变值进行替换,替换值为最近1周对应时刻流量数据的均值。例如,当今天5:00流量数据为极端异常值或长期不变值时,计算前7d 5:00流量数据的均值,并用该均值替换当前数据。对于由于数据缺失导致的不连续现象,可以使用相同的方法对缺失的数据进行填补。

2.2 特征提取

对于滑动窗口模型,提取 t 时刻及其前12个时刻的流量数据作为时间序列的滑动窗口,提取 t 时刻及其前7d相同时刻的流量数据作为时序序列的滑动窗口,时间间隔为1d。比较相邻滑动窗口统计特征的变化情况,如果特征值的变化率超过设定阈值,则判断为异常点。阈值的选取依赖于人工经验,可以适当降低门限值以保证尽可能少的漏报泄漏事件,本文中设置的阈值为0.1~0.2。

对于流量预测模型,提取 t 时刻及其前72个时

刻的流量数据作为时间序列,即LSTM网络层的输入;提取 t 时刻及其前7d相同时刻的流量数据作为时序序列,即LSTM网络层的输入;提取当天的天气和温度、工作日和休息日以及预测时刻所处的时间段(一天分为4个时间段:00:00—6:00, 6:00—12:00, 12:00—18:00, 18:00—24:00)作为ANN网络层的输入。对于离散型变量,采用One-hot编码方式。流量预测模型的最优结构和参数采用Grid Search网格搜索法确定,优化结果如表2所示。

对于残差聚类模型,提取 t 时刻及其前7d对应时刻的流量残差组成特征向量,然后将 t 时刻的流量残差依次减去特征向量中其他时刻的流量残差,从而得到1个关于 t 时刻流量残差变化率的特征序列,计算该序列的均值、方差、最大值和最小值。此外,提取 t 时刻及其过去2个月中每天 t 时刻的流量残差组成1个特征矩阵,按上述计算方法对特征矩阵的每1行进行处理,矩阵的每1行就代表着某

表2 流量预测模型结构与参数优化结果
Tab. 2 Flow Prediction Model Structure and Results of Parameter Optimization


项目	网络层参数
2个LSTM层和1个ANN层并联	LSTM神经元128,64,激活函数tanh;ANN神经元:128,激活函数relu
2个LSTM层和1个ANN层并联	LSTM神经元64,32,激活函数tanh;ANN神经元:64,激活函数relu
2个LSTM层和1个ANN层并联	LSTM神经元32,16,激活函数tanh;ANN神经元:32,激活函数relu
1个合并层	神经元:128,激活函数relu
2个全连接层	神经元:64,激活函数relu;神经元:32,激活函数relu
1个输出层	神经元:1,激活函数relu
其他参数	优化器:Adam;损失函数:Mean Squared Error;小批量训练样本数:32; 训练轮数100;训练结束:Early-Stopping

1天 t 时刻的流量残差变化率的特征向量。如果连续5个及以上时刻的流量残差都被识别为异常点,就判断DMA发生了漏损。K-Means模型中采用曼哈顿距离作为向量相似度的评估方法。


2.3 结果分析

图4所示为滑动窗口模型在2个试验小区的测试结果。可以看出滑动窗口模型对于凌晨泄漏试验的识别效果优于下午或晚上泄漏试验的识别效果,主要原因是试验小区在下午或晚上的用水量较多,泄漏流量的波动就显得相对弱一些,容易被正常用

水行为所覆盖;而在凌晨的时候用水量较少,泄漏流量的波动就容易被识别出来。例如,在试验小区二17:14—17:41期间开展的泄漏试验,泄漏流量占日均流量的118.2%,滑动窗口模型的识别准报率达到了100%,但是在试验小区一21:30—22:15期间开展的泄漏试验,泄漏流量占日均流量的7.9%,滑动窗口模型的识别准报率就只有33.3%。因此,滑动窗口模型适合检测流量波动较大的异常情况,如突发的流量峰值或突降,难以准确识别出一些微小的流量异常波动。



(a) 试验小区一的识别准报率



(b) 试验小区二的识别准报率

图4 滑动窗口模型的准报率

Fig. 4 Accuracy of the Sliding Window Model

图5为流量预测模型在2个试验小区上的测试结果。可以明显看出预测模型在试验小区一上的表现较好,预测精度高,平均绝对百分比误差为4.74%,而在试验小区二上的表现相对差一些,平均绝对百分比误差为12.08%。主要原因是试验小区二的用户数量少,流量数据中有不少阶梯状和零值

的出现,波动相对较大。

图6和图7为试验小区流量预测的残差分布情况,图中红色虚线框对应在现场开展的泄漏试验,可以发现泄漏发生时的流量残差分布和正常非泄漏时的残差分布不一样,尤其在凌晨的时候,流量残差有明显的异常波动现象。




图5 试验小区的流量预测曲线

Fig. 5 Flow Prediction Curve of the Experiment Area




图6 试验小区一的泄漏试验流量预测残差变化

Fig. 6 Predictive Residual Variation of Leakage Test in Experiment Area I




图 7 试验小区二的泄漏试验流量预测残差变化

Fig. 7 Predictive Residual Variation of Leakage Test in Experiment Area II

表 3 显示了泄漏识别模型在试验小区的测试效果。和滑动窗口法相比,残差分析法的识别效果明显提高,平均准报率约为 81.84%,误报率约为 3.87%,尤其是在白天进行的泄漏试验中表现更加突出。这种提升主要归功于采用了 K-Means 聚类方法分析流量残差的分布特征,将流量预测值与实际值之间的差异点聚类为不同类别。在泄漏试验中,流量异常所引发的残差变化往往与正常时段的残差

分布存在显著差异。聚类方法能够将这些具有明显特征的异常残差点划分为独立的异常簇,有效区分正常残差和异常残差,从而更加准确地捕捉到了泄漏事件的特征。

因此,尽管滑动窗口法的识别效果一般,但能够保障流量数据处理的时效性;而残差分析法则能够提升漏损信号检测的敏感性,有效剔除正常波动的干扰,从而精准识别异常变化。

表 3 泄漏识别模型的测试结果
Tab. 3 Testing Results of Leakage Identification Model

DMA 名称	试验日期	放水时间段	泄漏流量/ ($\text{m}^3 \cdot \text{h}^{-1}$)	滑动窗口法		残差分析法	
				准报率	误报率	准报率	误报率
试验小区一	8 月 9 日	21:30—22:15	2.489	33.3%		55.6%	
		22:22—22:52	4.311	50.0%	7.38%	83.3%	4.65%
		22:55—23:33	1.750	42.8%		57.7%	
	8 月 10 日	2:27—3:00	1.796	66.6%		83.3%	
		3:01—3:33	3.379	83.3%	7.14%	83.3%	4.09%
		3:36—4:10	4.731	85.7%		85.7%	
试验小区二	8 月 8 日	16:42—17:13	2.267	66.6%		83.3%	
		17:14—17:41	7.390	100.0%	6.39%	100.0%	3.21%
		17:42—18:10	1.635	66.6%		66.6%	
	8 月 9 日	2:52—3:22	1.901	83.3%		83.3%	
		3:23—3:53	3.594	100.0%	6.86%	100.0%	3.54%
		3:55—4:25	12.018	100.0%		100.0%	

3 结论

本文通过开展 DMA 小区泄漏试验,开发了基于三阶段动态分析的 DMA 漏损识别方法,主要用于识别 DMA 小区的新增漏损,用户以居民为主,流量数据的采样间隔不大于 15 min。可以得出以下结论。

(1)基于滑动窗口的流量异常诊断模型通过实时分析监测数据,可以及时发现流量的异常突变,适用于动态监测和预警。然而,该方法在泄漏识别方面的效果有限。

(2)基于 LSTM 的流量预测模型通过学习历史数据,能够高效地进行流量预测,准确捕捉用水趋势并减少误判。在流量波动较小的 DMA 小区,该预测模型的平均绝对百分比误差能够控制在 5% 以内;而在流量波动较大的 DMA 小区,预测模型的平均绝对百分比误差可能超过 10%。

(3)基于 K-Means 的残差异常识别模型通过对残差进行聚类分析,能够有效识别流量中的异常信号,进一步确认泄漏事件。在 2 个试验小区中均取得了良好的效果,模型的识别准报率约为 81.84%,误报率约为 3.87%,且在凌晨时段的识别效果优于白天,具有较好的实际应用前景。

未来的工作中,需要在更多不同用户类型和规模的 DMA 小区中进行测试,以验证该方法的有效性和稳定性,为大规模应用提供更为充分的数据支持和技术保障。

参考文献

- [1] 中华人民共和国住房和城乡建设部. 中国城市建设统计年鉴—2021[M]. 北京: 中国统计出版社, 2022.
Ministry of Housing and Urban-Rural Development of the People's Republic of China. China urban construction statistical yearbook[M]. Beijing: China Statistics Press, 2022.
- [2] Bozkurt C, Firat M, Ateş A. Development of a new comprehensive framework for the evaluation of leak management components and practices [J]. Journal of Water Supply: Research and Technology-Aqua, 2022, 71(5): 642–663.
- [3] 吴满勇. 分区计量法在城市供水漏损控制管理中的应用[J]. 净水技术, 2017, 36(7): 96–100, 114.
Wu X Y. Application of district metering areas (DMAs) in non-revenue water (NRW) management for urban water supply leakage and loss control [J]. Water Purification Technology, 2017, 36(7): 96–100, 114.
- [4] Farley M, Trow S. Losses in water distribution networks: A practitioners' guide to assessment, monitoring and control[J]. Water Intelligence Online, 2005, 4: 9781780402642. DOI: 10.2166/9781780402642.
- [5] Wu Y P, Liu S M, Wang X T. Distance-based burst detection using multiple pressure sensors in district metering areas [J]. Journal of Water Resources Planning and Management, 2018, 144(11): 06018009. DOI: 10.1061/(ASCE)WR.1943-5452.0001001.
- [6] Alfaro J L, Ortega J F. A comparison of robust alternatives to Hotelling's T^2 control chart [J]. Journal of Applied Statistics, 2009, 36(12): 1385–1396.
- [7] Huang P J, Zhu N F, Hou D B, et al. Real-time burst detection in district metering areas in water distribution system based on patterns of water demand with supervised learning [J]. Water, 2018, 10(12): 1765. DOI: 10.3390/w10121765.
- [8] Maußner C, Oberascher M, Autengruber A, et al. Explainable artificial intelligence for reliable water demand forecasting to increase trust in predictions [J]. Water Research, 2025, 268: 122779. DOI: 10.1016/j.watres.2024.122779.
- [9] Tornyeiadzi H M, Mohammed H, Seidu R. Robust night flow analysis in water distribution networks: A BiLSTM deep autoencoder approach [J]. Advanced Engineering Informatics, 2023, 58: 102135. DOI: 10.1016/j.aei.2023.102135.
- [10] 李旭, 林峰, 李允琛, 等. 基于组合流量法的城市供水系统小区漏损诊断和预警 [J]. 净水技术, 2024(2): 135–142, 183.
Li X, Lin F, Li Y C, et al. Diagnosis and early warning for water leakage loss of residential community in urban water supply system based on combined flow method [J]. Water Purification Technology, 2024(2): 135–142, 183.
- [11] Loureiro D, Amado C, Martins A, et al. Water distribution systems flow monitoring and anomalous event detection: A practical approach [J]. Urban Water Journal, 2016, 13(3): 242–252.
- [12] Zhou X, Tang Z H, Xu W R, et al. Deep learning identifies accurate burst locations in water distribution networks [J]. Water Research, 2019, 166: 115058. DOI: 10.1016/j.watres.2019.115058.
- [13] 马驰远, 雷国庆. 一种 CDC 信号滑动窗口时序分析方法 [J]. 计算机工程与科学, 2022, 44(2): 214–219.
Ma C Y, Lei G Q. A sliding window timing analysis method of CDC signals [J]. Computer Engineering and Science, 2022, 44(2): 214–219.
- [14] Glynis K, Kapelan Z, Bakker M, et al. Leveraging transfer learning in LSTM neural networks for data-efficient burst detection in water distribution systems [J]. Water Resources Management, 2023, 37(15): 5953–5972.
- [15] Abdunnassar A A, Nair L R. Performance analysis of Kmeans with modified initial centroid selection algorithms and developed Kmeans9+ model [J]. Measurement: Sensors, 2023, 25: 100666. DOI: 10.1016/j.measen.2023.100666.