

DOI:10.19853/j.zgjsps.1000-4602.2022.07.008

基于极限学习机算法的供水管网爆管识别研究

彭 森¹, 程 蕊¹, 吴 卿¹, 程 景¹, 孟 涛²

(1. 天津大学 环境科学与工程学院, 天津 300350; 2. 中国市政工程华北设计研究总院有限公司, 天津 300381)

摘 要: 供水管网爆管具有定位难、影响范围广的特点,长期困扰着供水企业。针对供水管网爆管区域识别问题,综合考虑多种影响因素下的爆管工况,利用爆管特征值矩阵构建爆管样本数据集,采用极限学习机算法(ELM)建立爆管区域识别模型;应用K-means聚类算法分析节点水力变化特征的相似性,并在此基础上对管网进行监测区域划分与监测点布设,形成多种监测方案;综合爆管识别率等参数,分析ELM在不同监测方案以及在噪声影响下的识别性能。采用实际管网算例进行了爆管区域识别分析,结果表明:该模型可以进行有效的爆管区域识别,同时结合不同分区方案可以提高爆管识别率;监测点的增加可以减小压力监测数据的噪声影响。

关键词: 供水管网; 爆管识别; 极限学习机算法; K-means聚类算法

中图分类号: TU991 **文献标识码:** A **文章编号:** 1000-4602(2022)07-0056-07

Identification of Water Supply Network Pipe Burst Based on Extreme Learning Machine Algorithm

PENG Sen¹, CHENG Rui¹, WU Qing¹, CHENG Jing¹, MENG Tao²

(1. School of Environmental Science and Engineering, Tianjin University, Tianjin 300350, China; 2. North China Municipal Engineering Design & Research Institute Co. Ltd., Tianjin 300381, China)

Abstract: Water supply network pipe burst has the characteristics of difficult location and wide range of influence, which has troubled water supply enterprises for a long time. To solve the problem of identifying the pipe burst area of water supply networks, the burst conditions were comprehensively considered under various influencing factors, the pipe burst sample data set was constructed by using eigenvalue matrix, and the model for identifying the pipe burst area was established by extreme learning machine (ELM) algorithm. The similarity of node hydraulic change characteristics was analyzed by using K-means clustering algorithm. On this basis, the monitoring area of the pipe network was divided and the monitoring points were arranged to form a variety of monitoring schemes. The identification performance of ELM under different monitoring schemes and noise impact was analyzed by combining the identification rate of pipe burst and other parameters. The burst area was identified and analyzed in a practical pipe network. It was found that the model could effectively identify the pipe burst area. At the same time, it could effectively improve the identification rate of pipe burst by combining different zoning schemes. The

基金项目: 国家重点研发计划项目(2016YFC0802400)

通信作者: 吴卿 E-mail: 13821060225@163.com

addition of monitoring points could reduce the noise impact from pressure monitoring data.

Key words: water supply network; identification of pipe burst area; ELM algorithm; K-means clustering algorithm

供水管网爆管事故是各供水企业普遍关注的问题,爆管不仅会导致大面积停水,浪费大量水资源,影响供水企业的经济效益,甚至会造成管网水质二次污染,影响城市供水安全。因此,及时识别供水管网爆管事故,对供水企业管理具有十分重要的现实意义。当前,爆管分析识别的有关研究主要是通过模型模拟或者 SCADA 系统实时监测,对爆管工况下的水力变化特征进行分析。李楠楠等人^[1]利用不同爆管工况下管网监测点压力与正常工况下的差值,建立最小二乘支持向量机模型,对爆管的位置及程度进行识别。Kang 等人^[2]分析爆管条件下管网压力响应,开发特定的爆管灵敏度表,将压力、流量监测数据与之匹配,识别潜在的爆管点。张晓云等人^[3]以监测点压力、流量变化为样本数据,构建 BP 神经网络,对漏失点位置进行定位。高相铭等人^[4]以小型给水管网为研究对象,利用基于人工蜂群算法优化的极限学习机(ABC-ELM)模型,预测非监测点的压降比。

随着对机器学习领域研究的不断深入,可以应用于供水管网爆管识别的方法也愈加丰富。国内外针对爆管问题进行的研究,主要侧重于算法性能的改进和比较^[5],多数研究的管网处于简单工况,在人为设定爆管流量后,对管网水力状态进行分析。由于供水系统的复杂性,将爆管识别算法与实际管网相结合还需要进行深入研究。

ELM 是一种基于前馈神经网络的单隐含层机器学习方法,相较于其他浅层学习系统,具有计算速度快、泛化能力强的优势^[6]。本研究结合华东某园区实际供水管网水力变化情况,在供水管网水力模型的基础上建立 ELM 模型,对爆管区域进行识别,并对不同监测方案下的 ELM 识别性能进行分析。

1 爆管识别方法

本研究依据以下步骤进行供水管网爆管区域识别分析,技术路线如图 1 所示。第 1 步,在构建供水管网模型的基础上,模拟管网多时刻、多节点、不同程度的爆管工况;第 2 步,以监测点在爆管发生前

后的压力变化率为基础,计算爆管特征值,在不同的爆管位置、程度、时间等条件下形成爆管特征值矩阵,记录与之对应的爆管所在监测分区信息,组合生成爆管样本数据集;第 3 步,建立管网压力敏感度矩阵,利用 K-means 算法对矩阵进行聚类分析,参考 K-means 样本核心位置布设监测点;第 4 步,依据管网地理位置和拓扑结构,考虑聚类分析结果,划分管网监测分区;第 5 步,构建 ELM 模型,将样本数据集输入模型进行训练,达到一定精度后,再输入新的样本数据集进行预测,通过爆管识别率来测试 ELM 模型的泛化能力,实现爆管区域识别功能。

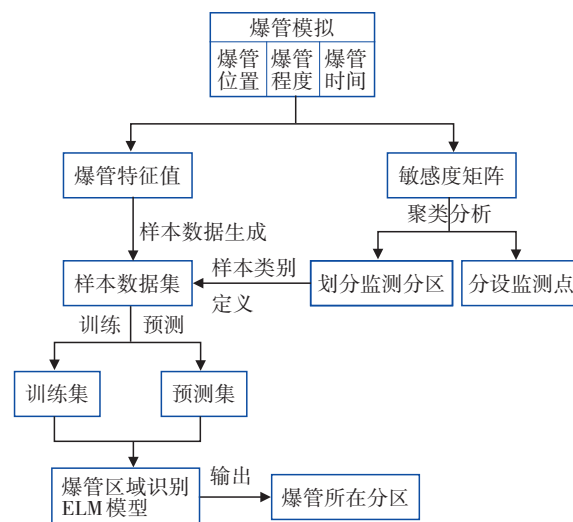


图 1 爆管区域识别技术路线

Fig.1 Technical route of pipe burst area identification

2 爆管模拟与分析方法

2.1 爆管流量计算

李诚^[7]根据小孔自由出流理论,引入参数 β 反映供水管网周围土体对水流的影响,提出爆管模型:

$$Q_{\text{爆}} = \beta \mu A_L \sqrt{2gH} \quad (1)$$

式中: $Q_{\text{爆}}$ 为管道爆管流量; A_L 为管道破损面积; H 为管道压力; β 取值 0.67; μ 为流量系数,取值 0.61。

赵丹丹等人^[8]采用漏失面积比表征爆管导致的管道破损程度,在爆管模型中引入该参数,得到管

网节点添加爆管流量公式:

$$Q_{\text{爆}} = \beta \mu \sigma A_D \sqrt{2gP} \quad (2)$$

式中: σ 为漏失面积比; A_D 为管道的截面积; P 为节点压力。

2.2 爆管特征值计算

建立供水管网模型后,通过在管网各节点添加爆管流量,模拟爆管工况下的管网水力状态。在某一时刻根据式(2)赋值漏失面积比 σ ,在节点处添加爆管流量。管网共有 s 个节点、 p 个监测点,假设在监测数据传输间隔期间在节点 i 处发生了爆管,产生了爆管流量 $Q_{\text{爆}}$,同时监测点 j 受到影响,其水压变化值为 ΔH_j 。由于同一时刻下每个监测点的压力不同,为了表征爆管对监测点自身的影响,本研究采用水压变化值与监测点被影响前压力的比值作为爆管点 i 对监测点 j 的影响度。

$$x_{ij} = \frac{H_j - H_j'}{H_j} \quad (i = 1, 2, \dots, s; j = 1, 2, \dots, p) \quad (3)$$

式中: x_{ij} 为影响度; H_j 为正常工况下监测点 j 的压力; H_j' 为被影响后监测点 j 的压力。

按照上述方法遍历管网节点后形成影响度矩阵 $[x]_{s \times p}$ 。为了将不同的影响度数据统一到同一数量级,方便后续数据处理,再将影响度矩阵 $[x]_{s \times p}$ 中各行元素进行 min-max 归一化处理,得到某一时刻下某一爆管程度的爆管特征值矩阵 $[x']_{s \times p}$ 。

$$x'(i, j) = \frac{x(i, j) - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中: $x'(i, j)$ 为节点 i 爆管时,监测点 j 的爆管特征值; $x(i, j)$ 为节点 i 爆管对监测点 j 的影响度; x_{\min} 为 $[x]_{s \times p}$ 第 i 行的最小值; x_{\max} 为 $[x]_{s \times p}$ 第 i 行的最大值。

综上,首先遍历管网所有节点计算影响度形成影响度矩阵 $[x]_{s \times p}$,然后再通过 min-max 归一化处理得到爆管特征值矩阵 $[x']_{s \times p}$ 。

2.3 压力监测点噪声影响

根据 Cheng 等人^[9]对监测点压力数据的研究,节点压力曲线在一段时间内并非一条光滑的曲线,而是存在着一定的噪声,在每 5~15 min 的传输间隔下呈锯齿状波动,并且压力波动的累积概率在 0.1~0.95 之间时服从正态分布,累积概率曲线的拐点可以设置为识别异常事件的阈值。因此,本研究在阈值内随机生成服从正态分布的数据 z ,并与监测点 j 被影响前后的压力差值相加,得到噪声影响下的影

响度矩阵 $[x_z]_{s \times p}$ 。

$$x_z = \frac{(H_j - H_j') + z}{H_j} \quad (5)$$

再经 min-max 归一化处理,进一步得到噪声影响下的爆管特征值矩阵 $[x_z']_{s \times p}$ 。

3 监测点及监测分区布置

3.1 节点压力敏感度

供水管网中一个节点的流量发生变化,必然会对管网其他节点压力产生不同程度的影响。本研究在 MATLAB 环境下调用水力模型,在高日高时从第一个节点开始,添加爆管流量并进行水力模拟,计算管网中 s 个节点在受到爆管影响产生的压力差值与该爆管点处压力差值的比值,形成 $s \times s$ 的数据矩阵后对列元素采用 min-max 归一化处理,得到爆管工况的节点压力敏感度矩阵^[10]。

通过聚类算法对节点压力敏感度矩阵的分析,能够将压力敏感度相似的节点归属到同一类别,并得到每个类别中最具有代表性的节点。依据聚类算法分析结果,结合拓扑结构、便于管理等因素,可确定供水管网监测点和监测分区的布置方案。

3.2 监测点的布设

K-means 作为一个无监督聚类算法,具有鲁棒性强、速度快等优点,是常用的数据聚类方法^[11]。该算法需要先设定样本中心的个数 k ,通过迭代计算数据集中每个点到样本中心的距离而进行聚类。为了保证监测点的数据具有代表性,本研究采用 K-means 算法,以节点压力敏感度矩阵为聚类对象,选取 k 个距离样本中心最近的节点,即最具有代表性的节点为监测点。此时,管网中不同的压力响应特征都可被监测点反映出来,且监测点数越多则对管网状态的监测越全面,但同时监测点之间的差异性越小,监测成本越高。因此,供水管网压力监测点并非越多越好,需根据监测目的合理布设监测点^[12]。本研究将进一步从爆管区域识别的角度,讨论监测点布置数量与爆管识别算法性能之间的关系。

3.3 监测分区的划分

受供水管网复杂性影响,一次性精确定位爆管发生的位置相对困难,因此可以先将管网划分成多个区块而形成监测分区,以确定爆管发生的大致区域,来缩小人工排查的范围。可以根据管网的布置情况、拓扑结构,同时考虑聚类结果,结合管网实际

管理维护便利性等因素划分监测分区。分区数越多则每个分区的规模越小,区内排查工作量越小,但数量过多不符合实际要求,因此分区数需要平衡两者关系后适当选取。

4 ELM爆管区域识别方法

4.1 样本数据集建立

根据2.2节所述,通过依次在管网所有节点添加爆管流量,按照式(3)计算监测点压力的变化率,在某一时刻下构建出相应的影响度矩阵 $[x]_{s \times p}$,按照式(4)计算得到爆管特征值矩阵 $[x']_{s \times p}$ 。随着模拟时刻、爆管流量的改变,管网水力状态随之改变,爆管特征值也会相应变化。考虑爆管位置、程度、时间的影响,本研究依次模拟每个管网节点在模拟时长内 t 个时刻、 g 个不同梯度的 σ 值所对应的爆管水力状态,即管网 t 个时刻、 s 个节点的 g 种爆管流量工况下 p 个监测点的影响度矩阵 $[x]_{tsg \times p}$,并经min-max归一化处理得到爆管特征值矩阵 $[x']_{tsg \times p}$ 。

考虑噪声影响时,在阈值内服从正态分布,随机生成数据矩阵 $[z]_{tsg \times p}$,将每个随机数 $z(i,j)$ 按照式(5)与影响度矩阵 $[x]_{tsg \times p}$ 进行运算,按照2.3节所述方法得到噪声影响下的爆管特征值矩阵 $[x'_z]_{tsg \times p}$ 。

判断某节点处发生爆管需要 p 个监测点爆管特征值共同表征,所以分别取 $[x']_{tsg \times p}$ 和 $[x'_z]_{tsg \times p}$ 矩阵的行向量作为ELM的样本数据 $X_i (i=1, 2, \dots, n; n=t \cdot s \cdot g)$ 。根据3.3节所述,每个爆管点都有与之相对应的监测分区,由此可以得到ELM的样本类别 $Y_j (j=1, 2, \dots, m; m$ 为设置的监测分区数)。

采用ELM算法进行爆管识别,需要建立爆管识别样本数据集 $D=\{<X_i, Y_j> | i=1, 2, 3, \dots, n; j=1, 2, 3, \dots, m\}$,其中 X_i, Y_j 分别为样本数据和样本类别。

4.2 ELM模型构建

样本数据 X 输入ELM模型后,在激活函数作用下,通过与输入权重 W 、偏置矩阵 B 、输出权重 Z 运算,得到输出的样本类别 Y ,其网络结构见图2。

本研究采用4.1节所述方法产生样本数据集,并作为ELM模型的训练集,再将其按7:3比例随机选取数据而分别形成学习集和验证集,当验证集满足一定精度后模型训练完成。因爆管程度具有随机性,爆管点处 σ 值是不确定的。为测试模型的泛化能力,在 σ 变化范围内再随机生成 g 个 σ' 值而生成新的样本数据集(定义为预测集),运用训练好的

ELM模型预测发生爆管的监测分区。

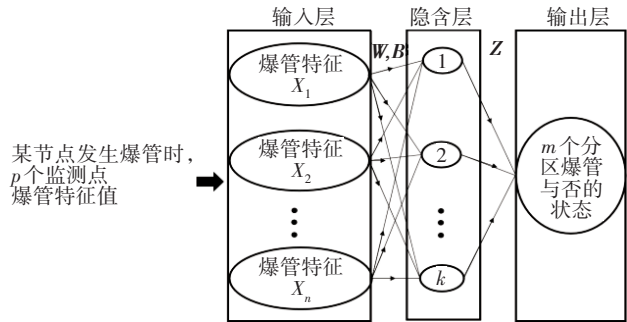


图2 基于ELM的爆管识别模型

Fig.2 Identification model of pipe burst based on ELM

在爆管识别模型训练或预测过程中,当ELM模型输出的爆管所在监测分区号与模拟爆管所在分区号一致时定义为正确识别,正确识别次数除以总识别次数即为识别率。由于训练ELM模型时,初始化输入权重 W 和偏置矩阵 B 具有随机性,所以将模型重复运行多次,取学习(预测)集识别率的平均值分别作为模型的训练和预测爆管识别率,以表征其性能。

5 实例分析

5.1 研究区域管网模型概况

选取华东某园区部分供水管网作为分析实例,其服务面积约为8 km²,最高日供水量为1.8×10⁴ m³/d, DN100以上管线总长约为24.7 km。收集整理供水区域概况、供水设施、管网地图、用水量等信息,经过管网合理简化建立EPANET模型,该模型共有464个节点、481根管段,如图3所示。



图3 研究区域管网模型示意

Fig.3 Schematic diagram of network model in studied area

通过SCADA监测数据,对管网模型进行校核,现状管网中3个压力监测点的压力实测值与模拟值之差均小于1 m水柱(1 m水柱产生的压力约为10 kPa,下同),2个流量监测点的流量实测值与模拟值相对误差均小于5%,符合一般情况下管网模型校核精度要求^[13]。

5.2 爆管区域识别分析

将漏失面积比 σ 设置为1,构建节点压力敏感度矩阵并用K-means算法进行分析,依次将管网节点划分为6、9、12、15、18、21、24个类别,每个类别下最具有代表性的节点设置为监测点。再结合拓扑结构、管理情况等因素将管网划分为6、12、18、24个分区,即 $m=6、12、18、24$ 。每种分区方案下设置6、9、12、15、18、21、24个监测点,即 $p=6、9、12、15、18、21、24$ 。因此,本研究共构建了28(4×7)种监测方案,其中24个监测分区、24个监测点的布置情况如图3所示。

依据4.1节所述方法,依次模拟管网464个节点00:00—24:00共25个时刻、5个不同漏失面积比 σ 对应的爆管流量及爆管水力变化情况。以0.5、0.75、1、1.25、1.5为一组 σ ,爆管工况为58 000($464 \times 25 \times 5$)种,生成爆管特征值矩阵 $[x']_{58\,000 \times p}$,该组数据为训练集1。在0.5~1.5的范围内随机选取一组 σ' ,生成预测集1。同时,根据对文献研究结果^[9]的总结,压力波动累计概率拐点对应的压力波动数值近似为-1 m和1 m水柱,因此本研究随机生成服从均值为0、标准差为1/3正态分布的数据矩阵 $[z]_{58\,000 \times p}$,按照2.3节所述得到噪声影响下的爆管特征值矩阵 $[x'_z]_{58\,000 \times p}$,该组数据为训练集2,并采用与上文相同的一组 σ' ,生成预测集2。

根据前人的研究经验和多次试算,ELM模型中选取Sigmoid函数作为激活函数,隐含层神经元个数为20,以爆管特征为样本数据,爆管所在监测分区号为样本类别,将ELM模型重复运行10次取平均值,得到不同监测点、不同分区条件下爆管识别率情况。

5.3 结果与讨论

对比ELM模型应用训练集1和预测集1得到的爆管识别率情况(见图4),两者基本一致,即便输入新的爆管特征值数据,爆管识别率没有明显下降,说明该ELM模型有较好的泛化能力,具有应用在实

际管网中的潜力。

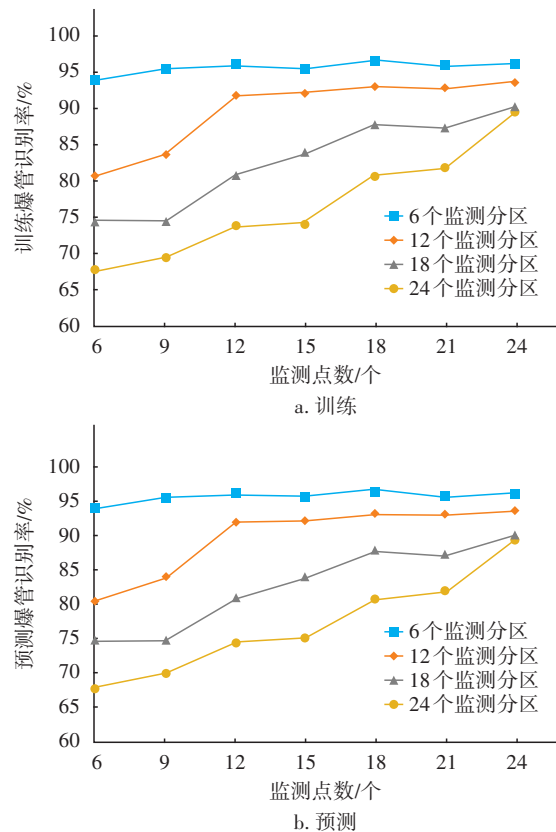


图4 爆管识别率比较

Fig.4 Comparison of pipe burst identification rate

在考虑噪声的情况下,ELM模型应用训练集2和预测集2得到的爆管识别率情况如图5所示。训练集2与训练集1相比,相同监测点个数、不同监测分区的识别率取均值时,布设6、9、12、15个监测点,识别率分别降低了5.4%、2.1%、2.2%、2.5%,噪声对识别算法性能有一定的影响;布设18、21、24个监测点,识别率分别降低了0.22%、0.01%、0.01%,噪声对识别算法性能基本没有影响,识别率与不考虑噪声时相似。说明在分析处理监测数据并加以应用时,增加监测点的数量有助于消除噪声影响。

无论是否受噪声影响,对比不同监测点和监测分区数下的识别率发现:当监测分区数一定时,随着监测点数量的增加,样本数据增多,管网压力状态变化的表征更全面,爆管识别率随之提高。同时,分区数越多,监测点增加对爆管识别率的提升效果越明显。当监测点数一定时,随着监测分区数量的增加,不同分区下的爆管特征值差异减小,爆管识别率随之降低。

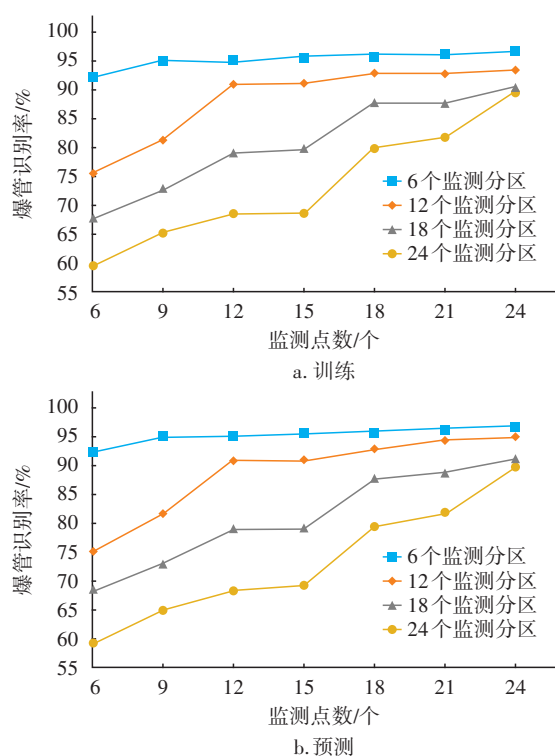


图5 噪声影响下爆管识别率比较

Fig.5 Comparison of pipe burst identification rate with influence of noise

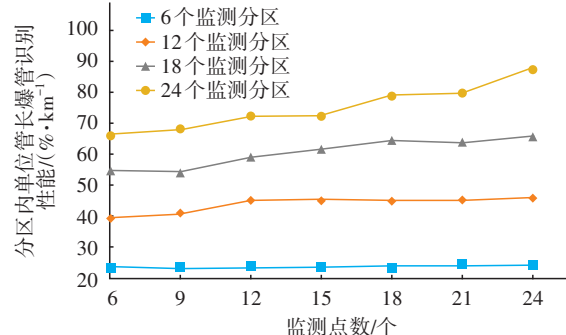
虽然监测分区数量增加会使得爆管识别率有所降低,但是不能把识别率作为模型识别效果的唯一判据,从而选择低监测分区数,还需要考虑不同分区下监测范围大小,综合分析ELM爆管区域识别性能。定义分区内单位管长平均爆管识别率 $\bar{\omega}$ 如下:

$$\bar{\omega} = \text{训练爆管识别率} / (\text{管线总长} / \text{分区数}) \quad (6)$$

由于噪声对识别效果的总体趋势并没有明显影响,且预测集和训练集识别效果相似,因此后续以训练集1所得识别率为例进行分析,对比不同监测方案的 $\bar{\omega}$,如图6所示。可以看出,监测分区数量越多,分区范围越小,分区内管线长度越少,相应的 $\bar{\omega}$ 越高,表现出更好的识别性能。监测分区越少,分区内管线长度越长,相应的 $\bar{\omega}$ 越低,识别分区后人工排查的任务量越大。

同时为进一步提高爆管识别率,可先进行24个监测分区下的识别计算,再放大监测分区范围进行识别。以布设24个监测点(具体位置见图3)为例,当管网划分为24个监测分区时,有13个分区爆管识别率高于85%,其余11个分区可以通过逐步放大监测分区范围的方式进一步识别(即扩展为18或12

个分区的划分方案进行识别)。扩展后这11个分区的识别率均达到85%以上,整体管网的爆管识别率由89.5%(单独采用24个监测分区进行识别)增加至93.7%。

图6 单位管长平均爆管识别率 $\bar{\omega}$ Fig.6 Average burst identification rate $\bar{\omega}$ per unit pipe length in sub-area

6 结论

提出了一种基于ELM算法对供水管网爆管区域进行识别的方法。综合考虑管网不同时刻、不同爆管位置和程度等因素,进行爆管水力状态模拟,建立爆管特征值矩阵,并通过ELM模型进行爆管区域识别。此外,还分别探究了不考虑和考虑压力监测噪声的情况下,不同监测分区、不同监测点数量与ELM模型爆管识别率之间的关系;通过适当增加监测分区数量,可减小爆管识别范围,同时结合不同监测分区方案再次进行识别,可进一步提高爆管识别率;通过适当增加监测点数量,有助于消除噪声影响。实例分析结果表明,该方法可以在管网监测分区下进行有效的爆管识别,并为人工巡检排查爆管事故提供参考。

由于研究条件限制,案例规模偏小,后续研究会考虑优化影响度函数,引入流量监测数据,加强与实际情况的联系,并对ELM模型参数矩阵进一步优化,以提高模型在实际监测下的爆管识别率。

参考文献:

- [1] 李楠楠, 鄢志红, 古田均. 供水管网爆管故障诊断的 PSO-SVM 方法[J]. 系统工程理论与实践, 2012, 32 (9): 2104-2110.
- LI Nannan, QIE Zhihong, FURUTA Hitoshi. PSO-SVM model for pipe bursting diagnosis of water supply network [J]. Systems Engineering—Theory & Practice, 2012, 32 (9): 2104-2110 (in Chinese).

- [2] KANG D, LANSEY K. Novel approach to detecting pipe bursts in water distribution networks [J]. *Journal of Water Resources Planning and Management*, 2014, 140(1):121-127.
- [3] 张晓云, 吕谋. BP神经网络在管网漏失方面的应用[J]. *环保科技*, 2019, 25(6):18-22.
ZHANG Xiaoyun, LÜ Mou. Application of BP neural network in pipeline leakage [J]. *Environmental Protection Science and Technology*, 2019, 25(6):18-22 (in Chinese).
- [4] 高相铭, 刘付斌, 杨世凤. 基于极限学习机的供水管网故障智能诊断方法[J]. *计算机工程与设计*, 2013, 34(8):2887-2891.
GAO Xiangming, LIU Fubin, YANG Shifeng. Intelligent fault diagnosis of water supply network based on ELM [J]. *Computer Engineering and Design*, 2013, 34(8):2887-2891 (in Chinese).
- [5] KAI C T, CHIN C S, ZHONG X H. Review of current technologies and proposed intelligent methodologies for water distributed network leakage detection [J]. *IEEE Access*, 2018. DOI:10.1109/ACCESS.2018.2885444.
- [6] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]// IEEE. 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541). Budapest, Hungary: IEEE, 2004. DOI: 10.1109/IJCNN.2004.1380068.
- [7] 李诚. 供水管网水力状态模拟及爆管信号识别研究[D]. 昆明: 昆明理工大学, 2017.
LI Cheng. Hydraulic Station Simulation on Water Supply Network and Study on the Identification of Pipe Burst Signal [D]. Kunming: Kunming University of Science and Technology, 2017 (in Chinese).
- [8] 赵丹丹, 程伟平, 许刚, 等. 供水管网系统爆管可监控最小管径分析方法研究[J]. *中国给水排水*, 2014, 30(23):117-122.
- ZHAO Dandan, CHENG Weiping, XU Gang, *et al.* Study on minimum detectable pipe diameter for pipe burst in water distribution system [J]. *China Water & Wastewater*, 2014, 30(23):117-122 (in Chinese).
- [9] CHENG W P, XU G, FANG H J, *et al.* Study on pipe burst detection frame based on water distribution model and monitoring system [J]. *Water*, 2019, 11(7):1363.
- [10] 彭畅, 彭森, 吴卿, 等. 基于NSGA-II的给水管网压力监测点多目标优化布置[J]. *中国给水排水*, 2019, 35(1):58-62.
PENG Chang, PENG Sen, WU Qing, *et al.* Multi-objective optimization of arrangement of pressure monitoring points in water distribution network based on NSGA-II [J]. *China Water & Wastewater*, 2019, 35(1):58-62 (in Chinese).
- [11] JAIN A K. Data clustering: 50 years beyond K-means [J]. *Pattern Recognition Letters*, 2010, 31(8):651-666.
- [12] 程伟平, 陈亚威, 许刚, 等. 基于遗传算法的供水管网爆管监控网络布置研究[J]. *中国给水排水*, 2020, 36(15):46-51.
CHENG Weiping, CHEN Yawei, XU Gang, *et al.* Layout of burst monitoring network in water distribution system based on genetic algorithm [J]. *China Water & Wastewater*, 2020, 36(15):46-51 (in Chinese).
- [13] 赵洪宾. 给水管网系统理论与分析[M]. 北京: 中国建筑工业出版社, 2003.
ZHAO Hongbin. Theory and Analysis of Water Supply Network System [M]. Beijing: China Architecture & Building Press, 2003 (in Chinese).

作者简介: 彭森(1981-), 男, 湖北武汉人, 博士, 副教授, 研究方向为市政工程给水管网优化。

E-mail: 13821060225@163.com

收稿日期: 2020-05-07

修回日期: 2020-09-20

(编辑: 任莹莹)