

DOI:10.19651/j.cnki.emt.2208905

基于 CNN 的供热管道泄漏识别方法研究 *

马广兴^{1,2} 曲波¹ 常琛¹ 卞浩然¹

(1. 内蒙古工业大学土木工程学院 呼和浩特 010050; 2. 内蒙古自治区土木工程结构与力学重点实验室 呼和浩特 010050)

摘要:为了快速识别出供热管道泄漏故障,以管道泄漏时产生的负压波特征,研究提出了利用卷积神经网络(CNN)识别压力数据的管道漏损诊断方法。通过搭建供热管道实验平台,采集了正常、泄漏、调阀三种工况下的压力数据作为卷积神经网络的训练集和测试集。对原始数据进行小波降噪处理,应用硬阈值的处理方法有效消除了噪声信号,同时在调阀工况中出现了强化特征,增强了卷积神经网络的分类能力。针对一维数据特征采用改进的 AlexNet 卷积网络模型对采集的数据进行学习及识别。结果发现,在对实验室数据测试中,CNN 模型的平均识别正确率达 98.39%。在对实际管网的验证中,三个热力站的泄漏数据均被正确识别,表明 CNN 模型具备良好的故障诊断能力。

关键词:泄漏检测;小波去噪;卷积神经网络;负压波

中图分类号: TU995 文献标识码: A 国家标准学科分类代码: 560.5540

Research on leakage identification method of heating pipeline based on CNN

Ma Guangxing^{1,2} Qu Bo¹ Chang Chen¹ Bian Haoran¹

(1. School of Civil Engineering, Inner Mongolia University of Technology, Hohhot 010050, China;

2. Key Laboratory of Civil Engineering Structure and Mechanics of Inner Mongolia Autonomous, Hohhot 010050, China)

Abstract: In order to quickly identify the leakage fault of heating pipeline, a method of pipeline leakage diagnosis using convolutional neural network (CNN) to identify the pressure data was proposed for the negative pressure wave characteristics of pipeline leakage. By setting up the experimental platform of heating pipeline, the pressure data under normal, leakage and regulating valve conditions are collected as the training set and test set of convolutional neural network. The original data are denoised by wavelet, and the hard threshold processing method is used to effectively eliminate the noise signal. Meanwhile, the enhancement feature appears in the valve condition, which is helpful to enhance the classification ability of the convolutional neural network. The improved AlexNet convolution network model is used to learn and identify the collected data. The results show that the average recognition accuracy of CNN model is 98.3% in laboratory data testing. In the verification of the actual pipe network, the leakage data of the three thermal stations were correctly identified, indicating that the CNN model has good fault diagnosis ability.

Keywords: leak detection; wavelet denoising; CNN; negative pressure wave

0 引言

随着供热管道规模的扩大和使用年限的增加不可避免的会发生泄漏问题,管道腐蚀和机械冲击是造成泄漏的主要原因^[1-2]。为了检测出管道泄漏问题,众多管道泄漏检测技术被开发使用,其中利用人工智能技术提高泄漏故障检测效率受到广泛关注。

现阶段用于实际的管道泄漏检测技术可分为两类:基

于硬件的方法和基于软件的方法。基于硬件检测的方法如光纤检测法^[3]、声学检测法^[4-6]、红外线成像法^[7-8]、漏磁检测法^[9]等在使用过程中成熟稳定,但该类方法投入成本较高或人工依赖性强,限制了这类技术的使用规模。

基于软件的方法是利用采集的数据进行的数据分析,其中极具代表性的有负压波检测法和神经网络法^[10]。负压波检测法具有成本低、灵敏度高、定位精度准等特点,但其不足在于经常受到调节工况的干扰而引起误报^[11]。而

收稿日期:2022-01-21

*基金项目:内蒙古工业大学科学研究项目(ZZ202012)资助

神经网络的方法因其强大数据学习能力具备一定的自适应性,因此近年来备受学者的青睐。在泄漏诊断方面通过神经网络结合不同类型的信号进行识别被证明是有效的。早期 BP 神经网络方法通过结合空间结构的管网泄漏工况水力计算模型,可以判断出泄漏管段^[12]。然而 BP 神经网络中存在收敛慢,易出现局部极值的问题,尽管可以通过优化算法提高识别能力。但 BP 神经网络方法由于管网空间拓扑结构复杂且神经网络训练的目标管网固定,对于变化的管网系统预测的泛化能力有待提升。深度学习算法是神经网络发展的又一里程碑,随着算法模型功能性的增强,各方法被不断尝试。以物理原理为指导训练的 LSTM 模型在测试中表现出了优异的精度,但是基于特定的物理过程训练的模型无法适应管网中复杂的流态变化^[13]。深度置信网络在管网故障诊断中可以达到 96.87% 的准确率^[14],但由于其学习参数较多,不易于扩展到不同的管网。采用卷积神经网络的方法将声信号图像分类,诊断结果表明卷积网络模型对低泄漏的诊断有效^[15],但是声信号与压力信号相比更容易受到外界干扰。总体而言,神经网络在信号的分类识别上表现出了良好的诊断能力,选择合适的神经网络和信号种类对管道的故障诊断有重要影响。

综上所述,本文提出了一种基于一维卷积神经网络的供热管道泄漏诊断模型,用于识别管道泄漏时的负压波,进而判断管道是否发生泄漏,降低误报率。

1 理论研究

1.1 负压波诊断泄漏方法及影响因素

供热管道突然发生泄漏时,泄漏处管道内外会产生压差,由于液体流动的连续性,管道中介质的流动速度不会发生瞬时改变,但在泄漏点介质会从管道上、下游向泄漏点补充,并在该位置上产生瞬间的压降,此后产生的压降以声速向管道上、下游扩散,这种扩散被称为负压波。利用负压波到达上下游的时间差最终可判断泄漏位置,负压波检测原理如图 1 所示。

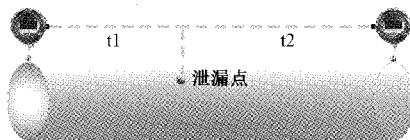


图 1 负压波法检测泄漏原理

事实上在管网系统中不只是泄漏会产生瞬时负压波,如阀门突然调节也会产生负压波,因此容易导致负压波法在模式识别上的误报,如图 2 所示。对比起始压力和结束压力相近的两种工况,调阀与泄漏情况下的压力下降曲线在斜率变化上出现不同特征,但人工很难判断。传统的方法需根据流量、压力两个参数共同判定是否为泄漏,但这种方法达到一定的值域范围才能报警^[16]。造成两种工况下的压降曲线差异的主要原因是两者的作用机理和影响参数

均不相同。管道泄漏引起的压降是管内外压差和液体连续性共同作用的结果。其压降与管道流速、负压波传递的波速及泄漏率的关系,如式(1)所示。在某一系统中,流量一定即管内流速一定,负压波的传递速度在固定的管道中可视为固定值,决定管道压降的变量取决于泄漏量。

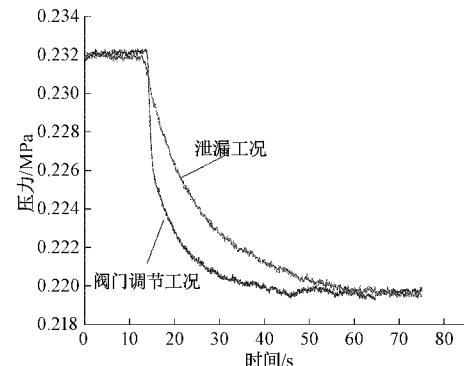


图 2 调阀与泄漏工况压降曲线对比图

$$|\Delta p_0| = \rho v \frac{mv_0}{2-m} \quad (1)$$

式中: v 为负压波波速,单位为 m/s; v_0 为管道泄漏前的流速,单位为 m/s; m 为泄漏率; $|\Delta p_0|$ 为泄漏点处的压力变化,单位为 Pa。

阀门对压降的影响取决于阀门的相对开度。在阀门关小的过程中,阀门的流阻系数会随之增加,阀后压力相应减小,如式(2)。而阀门在开度减小的过程中,流场变得复杂,会伴随着出现涡流,导致冲击与振动。

$$\Delta p = \frac{1 \times 10^{-6} \times KQ^2}{2\rho(A)^2} \quad (2)$$

式中: Δp 为阀门的压降,单位为 MPa; ρ 为流体密度,单位为 kg/m³; K 为流阻系数; A 为流通截面面积,单位为 m²; Q 为流量,单位为 kg/s。

所以阀门影响下的压降与管道泄漏的负压波引起的压降在作用机理上不同,决定压力下降幅度的影响参数也不相同。同时,两者在压降的过程中具有各自的流场特征,压降在下降过程中会表现出不同的时间压力轨迹。

1.2 小波分析的数据去噪

研究将采集的压力信号将载入卷积网络作为输入信息,带有噪声的信号会出现的不规则震荡会干扰神经网络的分类,因此需要进行小波的去噪处理。

小波分析是一种时域和频域的分析方法。母小波经过平移和伸缩操作后产生的函数簇即小波基函数与原信号的卷积运算可以得到小波系数,数学表达式为:

$$WT_x(m, n) = \frac{1}{\sqrt{m}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-n}{m}\right) dt \quad (3)$$

式中: m 为尺度因子,其作用是对母小波函数做伸缩; n 是平移因子反映平移的参数。 $\psi(x)$ 为母小波。

如果在每个可能的尺度下计算小波系数,计算量非常

大,须对小波进行离散化处理。离散小波变换的过程需要对参数 m 和 n 离散化,在实际应用中将 m 和 n 取幂级数进行离散化,常通过取 $m=2^j, n=2^{jk}$ ($j, k \in Z$) 来对尺度因子和偏移因子进行二进离散,其数学表示如下:

$$C_{j,k} = \int_{-\infty}^{\infty} 2^{-\frac{j}{2}} f(t) \psi(2^{-j}t - k) dt \quad (4)$$

小波去噪是对原始信号的多层次分解与重构,在每一层上找到相应的高频和低频的小波系数。高频系数通常代表着含有噪声的成分,低频系数则代表接近真实信号的成分。通过对小波系数设定阈值实现对高频信号过滤并保留低频信号,最终重构出去噪后的信号。所以在对小波去噪的过程中,选择合适的阈值是关键。本文采用的是硬阈值处理方法,该方法去除冗余信息方面具有很强的过滤能力可以有效降低噪声干扰,同时硬阈值去噪的方法在处理不同工况的信号时可以获取更大差异的输入信号,这有助于提高卷积神经网络的分类能力。

1.3 卷积神经网络

卷积神经网络(convolutional neural networks, CNN)是一种包含卷积运算的深层前馈神经网络。传统的神经网络每个神经元权重连接上层的所有神经元,所以会出现大量权重值,增加整个网络的数据量和复杂程度。CNN 则具有两个重要特征则是“局部感知”和“权值共享”,可有效提取数据的特征同时降低权值数量。完整的卷积网络通常包括卷积层、池化层、全连接层和输出层。

卷积神经网络的运行流程就是在卷积层进行特征提取,池化层进行进一步特征概括,最终通过全连接层进行分类的过程,流程如图 3 所示。根据数据的特征不同,卷积网络需要构建不同深度的网络结构,越复杂的数据越需要丰富的网络堆叠方式来提取数据的多层次特征。

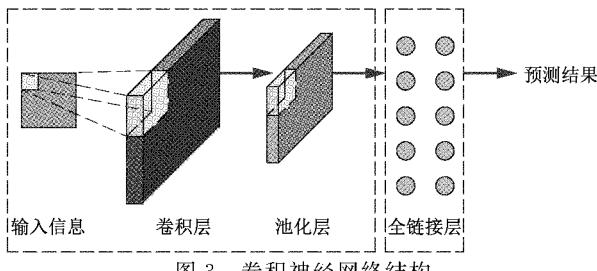


图 3 卷积神经网络结构

卷积层的提取数据特征的作用方式是通过卷积运算,使相同的卷积核根据固定的步长遍历数据。卷积核每遍历一个位置就和前一层中的神经元执行卷积运算,它是将矩阵中相同位置的元素直接相乘,然后求和的过程。在一维卷积神经网络中按照这个运算逻辑将卷积核矩阵根据步幅值继续向右滑动,直到覆盖整个输入矩阵,如图 4 所示。

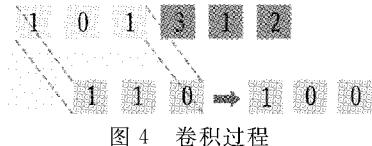


图 4 卷积过程

最后,得到卷积后的特征矩阵。在卷积层,输入由一组卷积核卷积得到新的特征映射经过激活函数处理传递至下一层,这个过程被描述为:

$$X_n = f(\mathbf{W}_n * \mathbf{X}_{n-1} + \mathbf{B}_n) \quad (5)$$

其中, \mathbf{X}_{n-1} 是上层数据经卷积层映射出的新矩阵。 \mathbf{W}_n 表示卷积核的权矩阵, \mathbf{B}_n 是该层的偏置矩阵, $*$ 表示离散卷积运算。 $f(x)$ 是激活函数,采用 Relu 函数。

池化层实现的功能则是对输入数据的降维和抽象,通过在空间范围内做维度约减,使模型可以抽取更广范围的特征,同时减少计算量和参数个数。池化采样主要分为两种方法:平均池化采样和最大池化采样。本文采用的是最大池化。池化过程如图 5 所示。

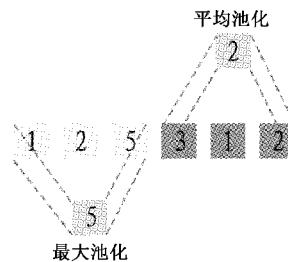


图 5 池化过程

最终卷积层和池化层提取的所有特征,在全连接层中以非线性地拟合输入数据用于分类。

2 实验研究

2.1 实验平台

研究搭建了供热管网实验台,通过实验模拟管道泄漏和调节工况,并利用实验采集的数据检验卷积神经网络诊断的有效性,实验现场如图 6 所示。管段基本特性如表 1 所示,实验设备及参数如表 2 所示。管道为长度 104 m,管径为 De50。实验管段通过设置水龙头来模拟泄漏点泄漏工况。泄漏点后端设置高精度压力传感器,电磁流量计位于泄漏点前端。测点布置如表 3 所示。所有设备采集的信号传输至电控柜内的采集模块,经 PLC 处理最终传输至上位机,实验系统原理如图 7 所示。由于供水温度不影响负压波的压力变化特征,故实验台采用冷水运行。

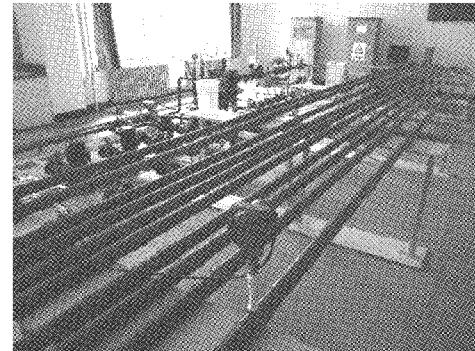


图 6 实验现场

表1 管道基本特性表

管道特性	管道长度	管道直径	管内流量	负压波波速
参数值	104 m	De50	1.88 m ³ /h	346.2 m/s

表2 实验设备及参数表

序号	设备名称	设备参数
1	数据采集卡	采集速率 40 kHz
2	高精度压力传感器	量程:0~1 MPa; 响应时间:100 ms
3	电磁流量计	仪表精度:0.5%; 量程:0~40 m ³ /h
4	循环水泵	流量:12.5 m ³ /h; 扬程:12.5 m; 转速:2 900 rm; 配电功率:1.1 kW
5	补水泵	流量:12.5 m ³ /h; 扬程:12.5 m; 转速:2 900 rm; 配电功率:1.1 kW

表3 测点分布表

测点名称	布置位置/m
泄漏点1	5
泄漏点2	8
泄漏点3	11

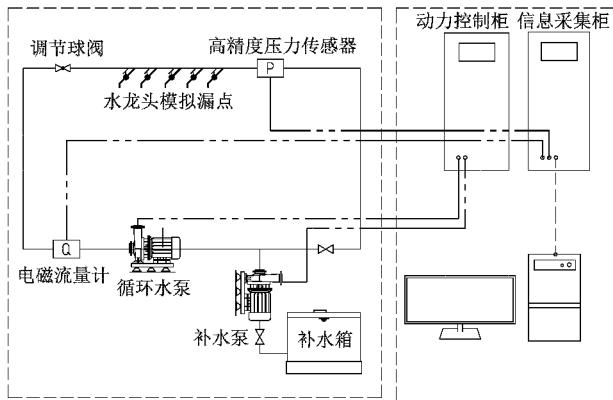


图7 实验原理

2.2 供热管道泄漏诊断流程

本研究通过采集实验室的实验数据,对卷积网络模型诊断效果进行测试,卷积神经网络的诊断流程如图8。本次实验共采集数据1 500组数据,其中正常工况数据500组,泄漏工况数据500组,调阀工况数据500组。选取各工况下的400组数据,作为训练集,100组数据作为测试集。数据采集的长度为1 500,采样频率为50 ms。泄漏点的泄漏范围在0.5%~15.4%,涵盖了低泄漏量到高泄漏量,可有效验证神经网络模型在各个泄漏区间的有效性。调阀数据采用手动调节球阀来采集,采集过程中阀门相对开度随机起始状态,通过对阀门不同调节量的操作获取不同程度的调节工况数据。

采集的数据输入至卷积网络模型前,需经过小波去噪

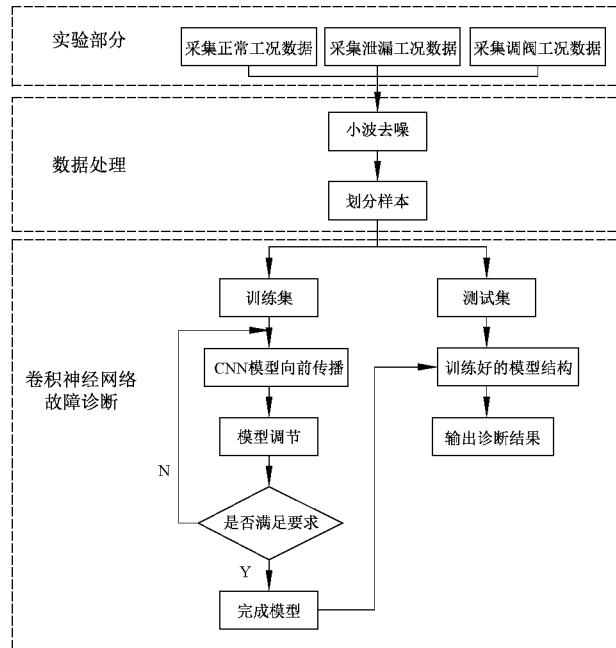


图8 诊断流程

的处理。研究发现原始数据直接输入到卷积网络中难以进行分类,识别率较低。这是由于噪声干扰及管道中微小的压力波动会产生大量的无效特征信息,导致卷积神经网络无法收敛。所以进行小波去噪是信号识别的关键环节。而后将处理后的信息载入卷积网络模型进行训练,对各类工况进行分类识别。

2.3 卷积神经网络的改进

本文使用的CNN模型是改进后的AlexNet模型。AlexNet模型一定程度上解决了模型较深产生的梯度弥散的问题,缓减了过拟合现象,增加了模型的泛化能力。但传统的AlexNet模型主要的目标对象是图片,针对管道压力的一维数据,本研究对AlexNet模型做了如下改进:

1)卷积核采用了一维卷积核,第一卷积层中原卷积核 11×11 调整为 1×7 的结构。不仅是在维度上做了调整,同时减少了卷积核的宽度,通过小卷积核的滤波可以提取更精细的特征。原结构中通道个数过于庞大,与处理图片不同,在一维数组中并不需要采用过多的通道来提取数据特征,对各层的通道数做了缩减,以减少模型不必要的运算。

2)删除了LRN层,因为LRN层的参数需要经过交叉验证,对模型的改善在实践中效果也非常有限,同时还会增加训练时间。

3)根据数据的复杂程度在全连接层上降低了神经元个数,第一个全连接层由原结构的4 096个神经单元调整至1 000个,减少了大量的冗余权值。

4)采用Adam进行权值参数优化,该算法采用学习率自适应的原则,较学习率固定的随机梯度下降算法,可以基于训练数据迭代更新神经网络权重,加快神经网络的收敛

速度且超参数的更新不受梯度伸缩变换的影响。

对模型调节一般通过加层来弥补性能。但在模型参数调节的过程中发现,加深网络结构对结果的影响不大,所以针对处理一维数据的 AlexNet 模型改进措施主要是削减不必要的网络结构,使整个神经网络更为简洁高效。改进的 AlexNet 参数详如表 4 所示。

表 4 AlexNet 模型参数设置表

层名称	核尺寸	输入通道	输出通道	步长	神经网络节点点数
卷积层 1	1 * 7	1	8	3	—
池化层 1	1 * 3			2	—
卷积层 2	1 * 5	8	16	1	—
池化层 2	1 * 3			2	—
卷积层 3	1 * 3	16	32	3	—
卷积层 4	1 * 3	32	4	1	—
卷积层 5	1 * 3	64	128	1	—
全连接层 3					1 000
全连接层 3					500
全连接层 3					3

3 结果与分析

3.1 小波降噪处理结果

本文选用的 coif2 小波对数据进行降噪,处理结果如图 9 所示。小波分解层数越高,压力信号曲线越平滑,但分解层数的增加也会将有用信息过滤,所以选择的小波层数应综合考虑信号的原始信息和去噪程度。通过对压力信号的去噪对比(如图 5),分解层数较低时,数据噪点不能有效去除;而分解到 10 层时数据已经趋于一条直线,丢失了细微的压力波动特征,所以小波层数的选取原则是寻找噪点去除较好且能反应原信号的分解层数,最终采用 coif2 小波 6 层分解处理信号。

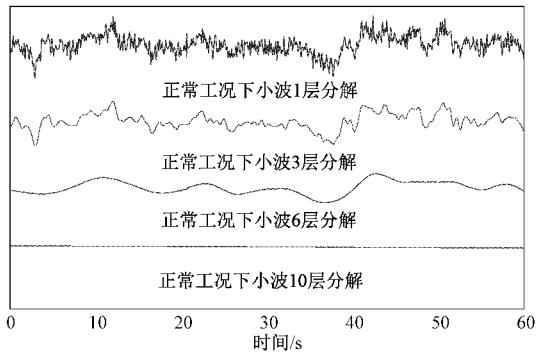


图 9 小波去噪分解层数对比图

经小波去噪的信号剔除掉了大量无用数据特征。从图 10、11 中可以看出,正常工况与泄漏工况处理后的曲线基本贴合原信号的曲线。处理后的信号无效噪点被很好的抑制,同时能很好的反映出原信号的主要波动特征。

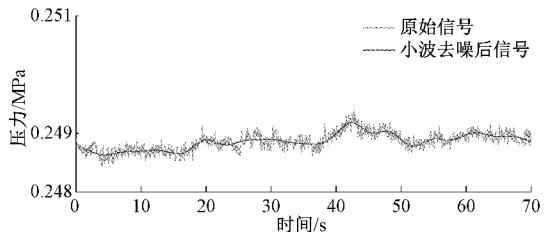


图 10 正常工况信号去噪前后对比图

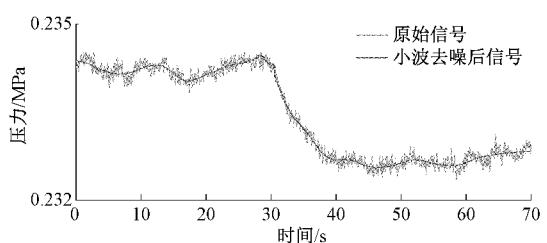


图 11 泄漏工况信号去噪前后对比图

处理后的阀门调节信号与正常、泄漏工况不同,压力曲线在起始的正常工况段和下降后的稳定段有良好的贴合度,但在下降段出现了一段不属于原有信号的震荡。这是由于硬阈值处理的信号在阈值处会出现不连续,进而引起的“伪吉布斯点”,如图 12 所示。而这一特点在正常工况和泄漏工况均不会出现。正常工况的压力曲线基本是在一条直线上的缓慢起伏波动。而泄漏工况的压力下降段是连续稳定的变化,不存在剧烈的变动,在阈值选取合适的情况下这两种工况的低频小波系数可以被很好的保留。而阀门调节的信号变化趋势是起始段陡降然后出现一段剧烈变化段之后再缓慢下降至平稳段,处于剧烈变化的这段曲线经小波去噪后会被解读为起伏震荡的特征,这就是因为小波系数在阈值处被归零处理后引起的过度解析。虽然这是一种偏离正常信号的处理结果,但在卷积神经网络中可以作为一种强化特征,对调阀工况进行分类,这也是本研究选取硬阈值作为处理方法的重要原因之一。

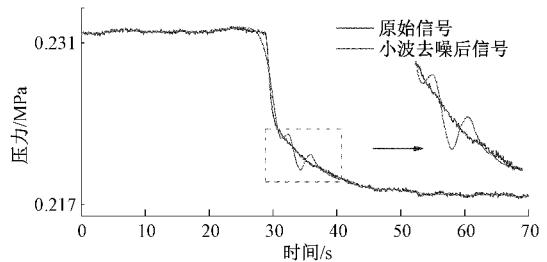


图 12 调阀工况信号去噪前后对比图

为了进一步验证通过硬阈值制造的“伪吉布斯”点来作为强化特征的适用性,对不同泄漏工况和不同调阀幅度的压力曲线进行对比分析。泄漏工况压力曲线平缓下降,类似于抛物线的下降轨迹直至稳定后基本成直线状态。随着泄漏量增加,曲线下降幅度随之下降,初始下降的斜率也随

之增加,但在所有的下降曲线中震荡特征未在这类工况里出现,如图13所示。调阀工况下,不同开度的调节影响了压力曲线的下降幅度,但无论是在哪个调节幅度下,压力曲线都会在斜率剧变处出现震荡,如图14所示。

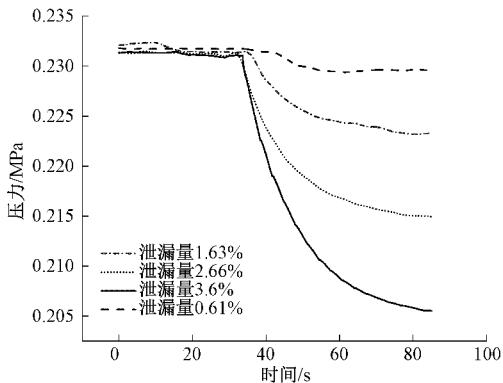


图13 不同泄漏工况下负压波变化曲线

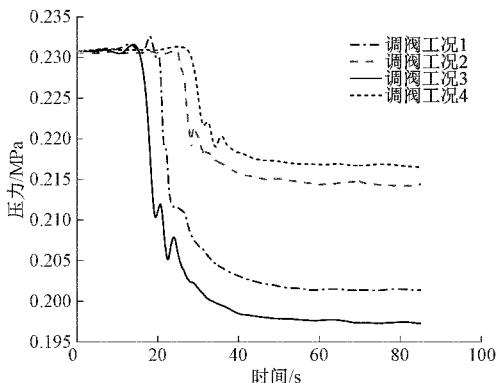


图14 阀门不同调节开度下负压波变化曲线

3.2 卷积神经网络的诊断结果

本文通过采用 AlexNet 卷积神经网络改进模型用于管道运行的压力工况进行分类。超参数是影响模型泛化性能的主要因素之一。通过反复试验,优化了两个超参数:学习率和批尺寸。学习率用于控制模型的梯度下降率,批尺寸大小用于调整模型的优化程度和速度。多次试验表明采用批尺寸参数大的准确率要略高于批尺寸小的,且在训练集和测试集上批尺寸越大损失函数的波动幅度越小。最终,模型的批量大小和学习率分别设置为 64 和 0.000 4。测试集在不同学习率和批尺寸情况下的识别率如表 5、6 所示。

表5 批尺寸大小的确定

批尺寸	8	16	32	64
准确率/%	96.8	95.8	96.5	99.3
损失函数	0.032 8	0.044 7	0.033 6	0.021

为了观察模型的性能,需要分析损失函数和准确率随迭代次数的变化情况,如图 15、16 所示。训练次数在 200 时,训练集与测试集的准确率就开始趋于平稳。模型训练集的

表6 学习率的确定

学习率	0.000 1	0.000 2	0.000 3	0.000 4
准确率/%	97.6	97.7	96.5	99.3
损失函数	0.035	0.034 4	0.039 9	0.021

损失函数波动较小,最终平稳收敛。模型在训练集上鲁棒性较好,但在测试集中,损失函数出现了相对较大的震荡,这与测试集样本容量有关,但模型的识别准确率仍可以维持在 96% 以上,具备较强的诊断能力。

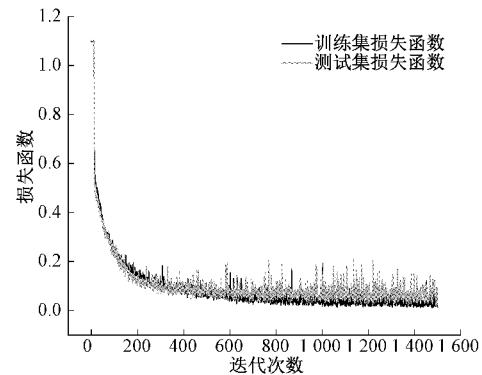


图15 损失函数图

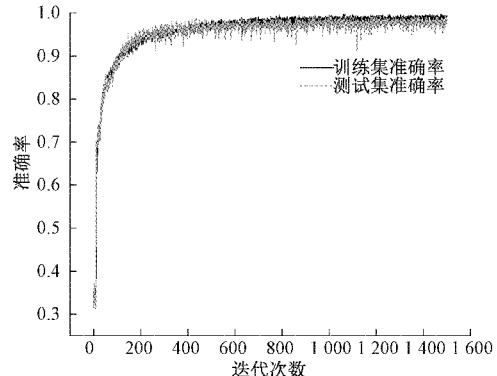


图16 模型识别准确率

对模型的单次诊断进行进一步分析,取模型在测试集上最优的参数为最终结果,得到的诊断结果正确率为 99.3%。图 17 为模型诊断的混淆矩阵图,横坐标代表真实值,纵坐标代表预测值,主对角线的数值代表模型预测的正确值。可以看出正常工况下的识别率可达 100%,其中 1 次调阀工况被诊断为泄漏工况,2 次泄漏工况被诊断为调阀工况。

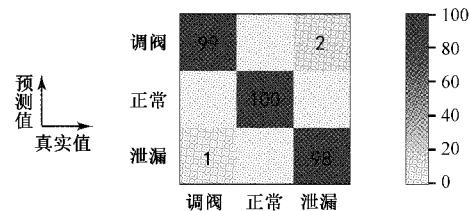


图17 混淆矩阵

这说明模型对正常工况识别的误报概率很低,而对于泄漏和调阀仍然存在一定程度的分类混淆,整体分类结果可以满足预期。

最终通过 10 次重复实验来进一步验证模型的鲁棒性。实验结果如表 7,其中模型的最低识别率为 98% 出现 2 次;识别率 98.33% 出现 5 次,为诊断结果中出现频率最高的;诊断结果准确率最高的为 99.3%,出现了 1 次;剩余的 2 次的识别率为 98.67%。最终模型在测试集上平均的识别率可达 98.39%,具有较强的分类能力。

表 7 识别准确率

识别结果	单次识别率			平均识别率/%
识别准确率/%	98	98.33	98.67	99.3
出现结果次数	2	5	2	1

3.3 CNN 泄漏检测技术对供热管网的实测

为了检验 CNN 识别的准确性,选择呼和浩特某供热单位一次供热管网的历史泄漏数据作为测试对象。2020 年该公司曾发生大型泄漏事故一次,此次事故中泄漏点周边的热力站点均有感应,各站点分布如图 18 所示。

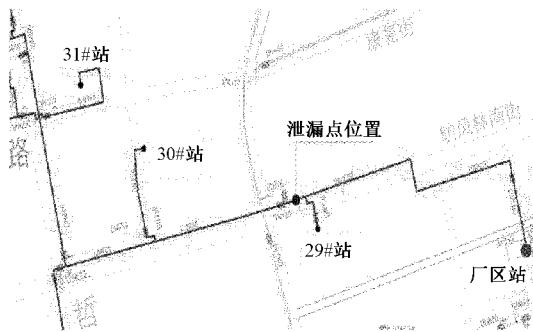


图 18 供热一次管网平面图

泄漏事故发生时,29#、30#、31# 站,出现明显压力下降曲线,如图 19 所示。图中压力下降段为管网受泄漏影响下的管道压力变化,管道经抢修后,曲线出现陡峭的上升趋势,并恢复到泄漏前的管网压力状态。由于工业管道的压力表精度有限,采样间隔较长,现场采样时间为每秒一次,因此曲线出现了一定程度的锯齿,但整体变化趋势与实验室一致。因此将抢修前的泄漏数据载入到 CNN 模型进行验证,测试结果表明三组数据均被识别为泄漏工况,证明模型具有一定的泛化能力,可以诊断出实际管网的泄漏工况。

对调阀工况及正常工况进行进一步的识别验证,供热管网对这两类的采样结果如图 20 所示。对这两类工况进行了五次独立试验,其中随机选取五组正常工况下数据载入至 CNN 模型;调阀工况的数据通过调节电磁阀获得,采集过程中选取不同起始开度调整至标准开度的数据,并将其载入 CNN 模型。

最终的识别结果如表 8 所示,对于正常和调阀两类工

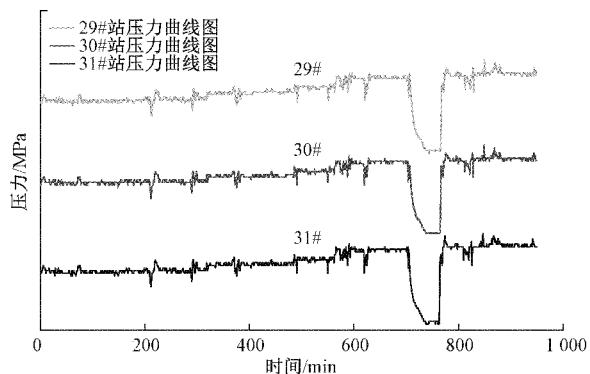


图 19 一次供热管网泄漏工况下管道压力图

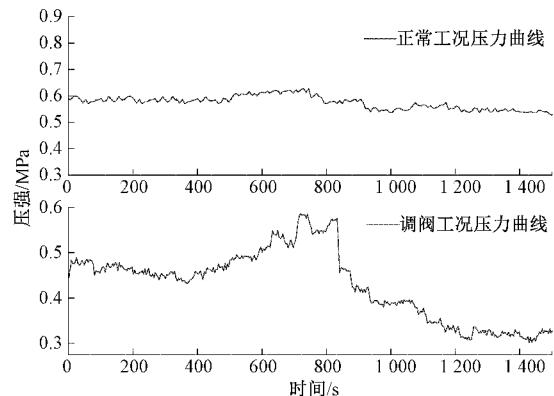


图 20 一次供热管网调阀及正常工况下管道压力图

况的识别准确率令人满意,没有出现误报情况。因此可以看出 CNN 模型可以基本判断实际管网所处的工况,但鉴于历史数据数量较少,模型的稳定性仍需进一步观察,特别是对于低泄漏的情况应逐步完善数据的监测及保存,用于模型的测试及样本的进一步学习。

表 8 工况识别情况表

工况类型	起始电磁 阀开度	结束电磁 阀开度	识别结果
正常工况 1	30	30	正常工况
正常工况 2	30	30	正常工况
正常工况 3	30	30	正常工况
正常工况 4	30	30	正常工况
正常工况 5	30	30	正常工况
调阀工况 1	40	30	调阀工况
调阀工况 2	45	30	调阀工况
调阀工况 3	50	30	调阀工况
调阀工况 4	55	30	调阀工况
调阀工况 5	60	30	调阀工况

4 结 论

本文结合小波去噪和改进 AlexNet 的一维卷积神经网

络,提出了一种可以识别管道泄漏故障的诊断方法。利用实验得到的正常工况、泄漏工况、调阀工况的压力数据作为学习样本,构建了适用于供热管网的泄漏故障诊断模型。

研究结果表明:

采用 coif2 小波的 6 层分解对原始信号进行去噪,处理结果能够消除掉了大量噪声信号,且在正常工况和泄漏工况下,处理后的信号与原信号有较好的贴合度。在调阀工况下,采用硬阈值的方法处理,可以获得强化特征用于提高卷积神经网络对这类信号的诊断能力,降低误报率。

针对一维数据对 AlexNet 模型结构进行改进,并且优化了学习率跟批尺寸两个超参数,建立了泄漏故障诊断识别模型,该模型对各类工况的平均识别率为 98.39%,最高识别率可以达 99.3%,可以有效诊断出管道的泄漏工况。

参考文献

- [1] HALLBERG D, STOJANOVIC B, AKANDER J. Status, needs and possibilities for service life prediction and estimation of district heating distribution networks [J]. Structure and Infrastructure Engineering, 2012, 8(1): 41-54.
- [2] ZORC B, KOSEC B, KOSEC L, et al. Analysis of hot water pipeline system leakage [J]. Engineering Failure Analysis, 2013, 28: 78-81.
- [3] REN L, JIANG T, JIA Z, et al. Pipeline corrosion and leakage monitoring based on the distributed optical fiber sensing technology [J]. Measurement, 2018, 122: 57-65.
- [4] 李玉星, 刘翠伟. 基于声波的输气管道泄漏监测技术研究进展 [J]. 科学通报, 2017, 62(7): 650-658.
- [5] 张梅, 张双双, 袁宏永, 等. 燃气管道泄漏的次声源定位算法研究 [J]. 电子测量与仪器学报, 2020, 34(3): 187-194.
- [6] 赵越, 赵英亮, 王黎明, 等. 基于 EEMD 的压力管道泄漏声源定位 [J]. 国外电子测量技术, 2021, 40(7): 128-132.
- [7] 李家琨. 气体泄漏被动式红外成像检测理论及方法研究 [D]. 北京:北京理工大学, 2015.
- [8] 张艳博, 任瑞峰, 梁鹏, 等. 基于热成像的埋地热力管道缺陷检测试验研究 [J]. 仪器仪表学报, 2020, 41(6): 161-170.
- [9] 杨理践, 孙丹, 高松巍. 直流励磁的管道壁厚漏磁检测技术 [J]. 无损探伤, 2015, 39(3): 9-12.
- [10] 郎宪明, 李平, 曹江涛, 等. 长输油气管道泄漏检测与定位技术研究进展 [J]. 控制工程, 2018, 25(4): 621-629.
- [11] SUN L, CHANG N. Integrated-signal-based leak location method for liquid pipelines [J]. Journal of Loss Prevention in the Process Industries, 2014, 32: 311-318.
- [12] 雷翠红, 邹平华. 供热管网的二级 BP 神经网络泄漏故障诊断 [J]. 哈尔滨工业大学学报, 2011, 43(2): 75-79.
- [13] ZHENG J, DU J, LIANG Y, et al. Deppipe: Theory-guided LSTM method for monitoring pressure after multi-product pipeline shutdown [J]. Process Safety and Environmental Protection, 2021, 155: 518-531.
- [14] 姚志强. 基于深度置信网络的管网泄漏故障诊断方法研究 [J]. 中国安全生产科学技术, 2018, 14(4): 101-106.
- [15] 李哲, 封皓, 刘欣, 等. 基于 CNN 的水管道小泄漏声信号识别 [J]. 噪声与振动控制, 2021, 41(4): 66-72.
- [16] 彭善碧, 廖柯熹, 李长俊, 等. 输油管道负压波法泄漏检测中的误报警排除法 [J]. 西南石油学院学报, 2006(1): 83-84.

作者简介

马广兴,博士,硕士生导师,主要从事供热系统与建筑节能、热泵技术与可再生能源应用研究。

E-mail:mgx126@126.com