

DOI: 10.13382/j.jemi.B2205550

基于深度学习的天然气钢制管道缺陷检测方法研究^{*}

梁海波 王 怡
(西南石油大学机电工程学院 成都 610500)

摘 要:在天然气钢质管道腐蚀缺陷超声检测中,常规模式识别采用人工提取回波信号的方法,存在主观性强、普适性低的问题。基于此,本文提出用一维卷积神经网络(one-dimensional convolutional neural network,1D-CNN)提取回波信号的特征结合随机森林(random forest RF)分类的方法。首先根据实验获取的回波信号的噪声情况,用小波包变换(wavelet packet transform WPT)对信号进行去噪;并用变分模态分解(variational model decomposition VMD)对去噪后的信号进行分解和重构以获得平滑的信号;最后将处理好的回波信号进行 1D-CNN 网络特征提取和随机森林分类。实验结果表明,基于 VMD-1D-CNN-RF 的天然气钢质管道缺陷检测方法针对人造缺陷的识别准确率为 85.71%,针对天然气站场的管道缺陷识别准确率为 71.05%,表明无需专家识别也可初步判别管道状况。

关键词:超声检测;变分模态分解;卷积神经网络;随机森林

中图分类号: TN06 ;TB529 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Research on defect detection method of natural gas steel pipeline based on deep learning

Liang Haibo Wang Yi
(College of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, China)

Abstract: In the ultrasonic detection of corrosion defects of natural gas steel pipelines, the conventional pattern recognition method adopts the method of manually extracting echo signals, which has the problems of strong subjectivity and low universality. Based on this, this paper proposes a method to extract the features of echo signals by using one-dimensional convolutional neural network and classify the features by combining with random forest. Firstly, according to the noise of the echo signal, the wavelet packet transform is used to denoise the signal. The denoised signal is decomposed and reconstructed by variational modal decomposition to obtain a smooth signal. Finally, the processed echo signals are extracted by 1D-CNN network features and classified by random forest. The experimental results show that the identification accuracy of the method based on VMD-1D-CNN-RF is 85.71% for artificial defects and 71.05% for pipeline defects in natural gas stations, indicating that the pipeline condition can be preliminarily identified without expert identification.

Keywords:ltrasonic detection; variational model decomposition; convolutional neural network; random forest

0 引 言

天然气钢制管道达到一定服役年龄后,其内部因化学腐蚀和物理伤害易产生形状不一的缺陷。如若不及时对缺陷进行检测和处理,会导致安全事故的发生,造成重大经济损失且威胁人民生命安全。超声波作为常用的无损检测方式,具有便携快速、操作简单的特点,广泛应用于天然气管道缺陷检测^[1]和大型储罐的缺陷检测中^[2]。

目前超声检测已经不再是纯粹地依靠专家对扫描结果进行评估,而是转向了检测自动化,依靠模式识别的方式通过机器学习实现对检测结果的自动评估^[3]。

在超声波缺陷检测模式识别中,特征提取常用域变换或者人工观察提取特征并结合主成分分析的方式。徐蒋明等^[4]用 3 种基于小波包变换(WPT)的特征提取方法,对焊缝缺陷回波信号提取特征,并将其作为 BP 神经网络的输入,达到了 85.71%的缺陷识别率。施成龙等^[5]利用小波包分解结合深度神经网络对人造缺陷进行识

别,结果表明准确率比 BP 神经网络高 21.66%。Legendre 等^[6]将回波信号进行小波变换 (wavelet transform, WT),将其中的小波系数作为人工神经网络的输入,完成了对焊缝缺陷的检测。罗来齐^[7]使用主成分分析法,对超声导波缺陷回波信号进行降维处理,结合支持向量机有效识别了人工预制的孔洞、裂纹和凹坑 3 类管道缺陷。唐东林等^[8]利用主成分分析和支持向量机的方法对超声波管道腐蚀缺陷深度信号进行分类。但这些提取方式均为人工提取特征,太具主观性,针对不同的对象存在不同的方法,因此提取特征的方式尚未形成统一的标准。

近年来,卷积神经网络越来越多地应用在无损检测中,其具有能自动提取特征的优点,其中一维卷积神经网络 (1D-CNN)更是可以直接对声音信号进行特征自动提取和分类^[9]。学者们用 1D-CNN 作为特征提取和分类的结构,实现了对航空发动机^[10]、刀具磨损^[11]和轴承故障^[12]的预测和诊断。Luo 等^[13]用 1D-CNN 网络实现了对 SLM 工艺中的金属溅射、裂纹和气孔缺陷的识别。Pandey 等^[14]用 1D-CNN 网络实验了对铝板损伤的自动超声检测。研究表明 1D-CNN 网络结构能够有效提取声音信号的特征。运用深度学习需要有大量的数据作为支撑,由于本文实验数据有限,因此本文提出运用 1D-CNN 网络提取超声检测回波信号的特征,同时结合机器学习的方法对特征进行分类。

传统特征分类多用神经网络^[15]、支持向量机^[16]和随机森林^[17]等方法。Jing 等^[18]用 BP 神经网络对 14 个反映不同点焊类型的超声特征信号进行自动识别和分类。但神经网络内部计算过程是盲盒状态,且存在训练时易陷入局部最优的缺点。Zhang 等^[19]研究了识别缺陷损伤严重程度和方向的有效性,利用支持向量机 (support vector machine, SVM) 对 17 种不同类型的损伤畸形数据分类。但支持向量机面对多分类问题时,将多分类问题转化 N 个二分类问题会导致分类效果变差。随机森林在目前的分类算法中精度最高,因此本文提出用随机森林对特征进行分类。

综上所述,本文提出了一种基于深度学习的天然气钢制管道缺陷检测方法。首先用小波包变换对天然气钢质管道缺陷回波信号去噪,将去噪后的信号进行 VMD 分解和重构。完成信号重构之后,用 1D-CNN 对重构的信号进行特征提取,同时针对数据有限用随机森林实现对特征的训练和分类。

1 超声检测原理和数据

1.1 人造缺陷

由于实际缺陷难以获取,为得到缺陷检测规律,需要

人为制造缺陷进行模拟实验。根据文献[20-21]的研究,制造了如图 1 所示的人工钢板缺陷,其中钢板材料和天然气管道是一致的,具体的缺陷数据如表 1 的 1~6 列所示。



图 1 人工钢板缺陷
Fig. 1 Defects of artificial steel plate

表 1 缺陷数据
Table 1 Defect data

缺陷类型	形状	缺陷个数	缺陷尺寸		间隔	实验数据 标签			
						次数	200	200	1
圆柱体		50	直径/mm	2~6	1	4	200	2	
			高/mm	1~10	1				
立方体		50	长/mm	2~5	1	4	200	3	
			宽/mm	2~5	1				
			高/mm	1~5	1				
圆锥体		50	直径/mm	2~6	1	4	200	4	
			高/mm	1~10	1				
椭圆		50	长轴/mm	0.5~2.5	0.5	4	200	5	
			短轴/mm	1~5	0.5				
不规则 1 (类圆)		50	面积/ mm ²	≈4π~(2~6) ² 36π		4	200	6	
			高/mm	1~10	1				
不规则 2 (类立方体)		50	面积/ mm ²	≈4~36 (2~6) ²		4	200	7	
			高/mm	1~10	1				

1.2 超声检测原理

本文用多次脉冲检测法检测缺陷,以多次底波为依据进行探伤,图 2 为原理图。当探头发射的超声波由底部返回至探头时,一部分回波被探头接收,另一部分回波折回底部,如此往复直到能量衰减完毕为止。工件内有吸收性缺陷(孔、间隙等)时,声波在此处衰减很大,发射底波次数减少甚至消失。图 2 中 A 为有缺陷时的超声检测, B 为无缺陷时的超声检测。




图 2 超声缺陷原理

Fig. 2 Principle of ultrasonic defects

通常满足式(1)的两个条件时,超声波将发生瑞利散射。其中 λ 为波长, d 为缺陷直径, α 为超声波衰减, β 为平均晶粒体积, S 为材料系数。超声波遇到缺陷时,其散射波不沿着纵向传播,导致声波散射衰减相较于纵向传播的 B 更多,因此回波衰减更厉害,同时反射波 C 又以 θ 角度反射,使得波程变大,能量衰减更严重。

$$d < \lambda, \frac{\alpha}{\beta S} \rightarrow f^4 \quad (1)$$

从回波衰减的角度来看,由于缺陷不同而导致回波信号不同,根据汤普森-格雷测量模型,换能器占据 A 区域的缺陷接收到的回波信号幅值可以建模如下:

$$a = \frac{1}{4P} \int_A i\omega (\omega^2 \delta \rho u_i^0 u_i - \delta c u_{ij}^0 u_{ij}) d\Omega \quad (2)$$

其中, P 是电功率, $\delta \rho$ 是基底材料和缺陷之间密度差, δc 是弹性常数差异, ω 是超声波的角频率, u_i 是粒子极化,上标 0 表示无缺陷的场变量。如果散射体密度变化可以忽略,则上式简化为:

$$a = \frac{i\omega^3}{4P} \int_A (\delta \rho u_i^0 u_i) d\Omega \quad (3)$$

如果超声波遇到缺陷则 $P > 0$, 那么幅值 a 就会减少得更快,因此可以通过波形的变化判断缺陷的情况。

1.3 超声检测过程

本文超声波检测参数为:超声探头激发电压为 300 V,在激发电压作用下压电陶瓷发出稳定的脉冲;探头中心频率为 2.5 MHz,其直径为 20 mm,探头集收、发的功能于一体;回波的显示和采集由示波器完成,示波器的最高采样频率为 100 MHz。超声检测过程如图 3 示,图 4 为超声

检测实验图。将超声探头均匀涂抹上耦合剂放置在钢板的表面上,通过电路板产生激发电压使得超声探头发射出声波。声波在钢板里面传播,遇到缺陷或到达底部时被反射,反射波被探头接收,通过示波器完成对信号的显示和采集,存储的文件类型为 .CSV。完成存储后,重复实验。最后将回波在 PC 端进行信号处理,完成信号预处理之后,将信号进行特征提取和特征分类以实现钢板缺陷的自动识别,实验数据记录在表 1 的 7~9 列中。




图 3 超声检测过程

Fig. 3 Ultrasonic testing process




图 4 超声检测实验图

Fig. 4 Experimental diagram of ultrasonic detection

2 超声回波信号处理

2.1 回波去冗余和去噪

实验获取的回波包含了大量的噪声和冗余信息,如果不去除冗余信息和噪声,则很难从原始信号中提取出有用的信息。如图 5 示依据经验和观察,对实验结果仅保留前 7 个回波信号。

缺陷回波产生噪声的主要原因有:1)由电路产生的电子噪声;2)由超声波从材料的微观结构特征如晶界反射引起的后向散射噪声。回波噪声使得无论是机器还是人工对于波形的识别均变得很困难。常用的回波去噪算法有离散小波变换(DWT)、平稳小波变换(SWT)、小波




图5 去冗余后的超声检测回波

Fig. 5 Ultrasonic echo detection after redundancy removal

包变换 (WPT) 等方法, 其中 WPT 在滤波和去噪效果上表现最好。在 WPT 中, 小波基函数的选择会直接影响到去噪算法的有效性, 所以无论是小波变换还是小波包变换都需要选择合适的小波基函数。常用的小波基函数有 Haar 小波, Daubenchies 小波, Biorthogonal 小波, Symlets 小波, Mexican Hat 小波等。根据文献[22]中的表述, 用该方法作为阈值选择准则, 设置最大的分解层数为 4 层, 并用信噪比 (signal-noise ratio, SNR), 峰值信噪比 (peak signal-noise ratio, PSNR), 均方根 (root mean square, MSE) 作为选择的指标, 其计算公式如下:

$$SNR = \frac{P_{signal}}{P_{noise}} = \frac{A_{signal}^2}{A_{noise}^2} \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=1}^m \omega_i (signal - original_signal)^2 \quad (5)$$


$$PSNR = 10 \times \log\left(\frac{\text{MAX}(signal)}{MSE}\right) \quad (6)$$

选择小波基函数的过程为: 首先将原始信号进行小波包分解, 其中分解的核函数是各种小波基函数; 接着通过设定的阈值将其中低于阈值的小波系数清零; 然后计算信号的信噪比, 通过将不同方法的去噪结果进行对比, 选择出最优的小波函数对缺陷信号进行去噪处理。其中最优的判定方式为对比 SNR、PSNR 和 MSE 值的大小。

各种小波基函数去噪的结果如图 6(a)、(b) 所示, 指标如表 2 所示。实验结果表明 *coif2* 小波基函数有最高的信噪比、峰值信噪比和最低的均方根, 因此选择 *coif2* 作为去噪的核函数, 对所有的信号进行去噪处理。


2.2 回波分解重构

观察图 6(a)、(b) 可知去噪后的信号尚不平滑, 因此为了获得更加平滑的信号需要对信号进行分解和重构。本文提出用变分模态分解 (variational model decomposition, VMD) 对信号进行分解和重构。VMD 是一种自适应完全非递归的模态变分和信号处理方法, 通过



(a) 前4种不同小波基函数去噪结果

(a) Denoising results of the first four different wavelet basisfunctions



(b) 后4种不同小波基函数去噪结果

(b) Denoising results of the last four different wavelet basisfunctions

图6 小波基函数去噪结果

Fig. 6 Wavelet basis function denoising results

VMD 提取能够表征原始信号的本征模态函数并重构信号, 进而可以得到包含大量原始信号信息且更加间接平滑的信号。VMD 方法如下, 首先一个简单的信号被表示为式(7):

$$x(t) = A(t) \cos(\varphi t) \quad (7)$$

其中, $A(t)$ 为幅度函数, φ 为瞬时相位, 假设原始信号 $x(t)$ 被分解为 k 个分量, 为了保证分解信号为具有中心频率的有限带宽的模态分量, 同时各模态的估计带宽之和最小, 约束条件为所有模态之和且等于原始信号, 则相应的约束变分表达式为:

表 2 小波基函数去噪效果对比

Table 2 Comparison of denoising effects of wavelet basis functions

小波基函数	指数		
	SNR	PSNR	MSE
sym4	2.894 7	20.331 2	1.567 4
coif2	2.964 3	21.316 3	1.542 5
db3	2.847 1	20.631 5	1.584 7
dmey	2.944 4	21.124 8	1.549 6
bior1.5	2.775 4	20.155 0	1.611 0
fk4	2.849 2	20.653 6	1.583 9
haar	2.733 4	21.134 1	1.626 7
rbio1.5	2.870 0	20.699 9	1.576 3

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\}$$
$$\text{s. t. } \sum_{k=1}^K u_k = f \tag{8}$$

其中, k 为需要分解的模态个数, $\{u_k\}, \{\omega_k\}$ 分别对应分解后第 k 个模态分量和中心频率, $\delta(t)$ 为狄拉克函数, $*$ 为卷积运算符。为了求解这个式子, 引入 Lagrange 乘法算子, 将约束变分问题转变为非约束变分问题, 得到增广矩阵 Lagrange 表达式为式(9):

$$L(\{u_k\}, \{\omega_k\}, \lambda) =$$
$$\alpha \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 +$$
$$\left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \tag{9}$$

其中, α 为二次惩罚因子, 其作用是降低高斯噪声的干扰。对于上述式子的求解, 首先利用交替方向乘子 (ADMM) 迭代算法结合 Parseval、傅里叶等距变换, 优化得到各模态和中心频率, 并搜寻增广 Lagrange 函数的鞍点, 交替寻优迭代后的 $\{u_k\}, \{\omega_k\}$ 和 λ 的表达式如下:

$$\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2$$
$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \tag{10}$$

$$\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega$$
$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \tag{11}$$

$$\hat{\lambda}n + 1(\omega) \leftarrow \hat{\lambda}n(\omega) + \gamma(\hat{f}(\omega) - \sum_k \hat{u}n + 1_k(\omega))$$
$$\tag{12}$$

完成上述流程之后, 利用迭代的方式完成对信号的分解。然而确定信号的分解层数依然是一个问题, 欠分解会造成分解不完全, 过分解会造成高频分量出现断断续续的现象。为了解决过分解的现象, 给出一种利用平均瞬时频率对分解层数进行判断的方法, 以此寻求最佳的分解层数。由于过分解会造成高频部分的信号出现不连续的情况, 因此如果出现过分解, 则其平均瞬时频率将

会出现突变或者包含断点等状况。首先假设分解的信号为式(13):

$$u(t) = [IMF_1, IMF_2, \dots, IMF_k] + residual \tag{13}$$

其中, $u(t)$ 是原始信号, k 表示分解的层数, 其大小为 $k = 1 \sim$ 设定的分解层数。接着对分解的信号进行 Hilbert 变换:

$$H[u_k(t)] = \tilde{u}_k(t) = \pi^{-1} \int_{-\infty}^\infty \frac{u_k(\tau)}{t - \tau} d\tau \tag{14}$$

则瞬时频率为:

$$\omega_k(t) = \frac{u_k(t) \tilde{u}_k'(t) - u_k'(t) \tilde{u}_k(t)}{A^2(t)}$$
$$\tag{15}$$

接着对瞬时频率求平均值:

$$\bar{\omega}_k(t) = \frac{1}{N} \sum_{i=1}^N \omega_k(t)$$
$$\tag{16}$$

根据上式, 如果产生了过分解, 则其平均瞬时频率会出现明显的转折。最后将最优分解个数的本征模态函数重构就能得到重构后的信号。对任意一个去噪后的信号进行分解实验, 结果如图 7 所示。从图中可以看出当 $K = 3$ 时, 后面的图形就出现了明显的转折, 因此选择分解层数为 3 层。




图 7 VMD 分解层数

Fig. 7 Number of VMD decomposition layers

由上述信号分解过程可知信号被分解 3 次, 后续的信号将被丢弃, 因此选择前 3 个信号进行重构。从图 8 可以看出, 重构信号相较于原始信号更加平滑, 消除了因为采样率而造成的机械直角形状, 提高了信号的品质, 使得信号的后续处理更加容易。同时重构信号和原信号相比几乎重合, 但是重构信号更加光滑, 这说明重构信号并不影响原始信号的属性, 几乎保留了原始信号的所有特

征。同理求出所有信号的重构信号,由于篇幅所限,图 9 只展示 12 个信号的重构回波图。表 3 为重构信号和原始信号的相关系数,从二者的相关系数为 0.991 5 来看,重构信号和原始信号非常相关。从图 9 中可以看到前 7 个缺陷回波信号,每个缺陷回波信号的幅值以及其他特性是不一致的。




图 8 重构信号和原始信号的对比

Fig. 8 Comparison of reconstructed signal and original signal




图 9 12 个信号的重构回波图

Fig. 9 Reconstructed echo diagram of 12 signals

表 3 重构信号和原始信号的相关系数

Table 3 Correlation coefficients between reconstructed signals and original signals

信号	相关系数	信号	相关系数
1	0.991 5	7	0.991 6
2	0.991 7	8	0.992 0
3	0.991 8	9	0.990 7
4	0.991 3	10	0.991 7
5	0.991 9	11	0.991 4
6	0.989 7	12	0.992 0

3 D-CNN 特征提取

3.1 1D-CNN 结构和参数

图 10 为典型一维卷积神经网络的结构示意图,主要包括输入信息(处理后的回波信号),中间层和输出层。中间层包含卷积层、池化层和全连接层,卷积层需要用激活函数进行激活,在中间层中有的结构加了 Dropout 层和批归一化层,目的是简化运算并且提高网络的泛化能力。网络的运算主要包括前向传播和反向传播两个部分。




图 10 典型一维卷积神经网络的结构示意图

Fig. 10 Structure diagram of typical one-dimensional convolutional neural network

卷积神经网络的前向传播,首先将处理好的超声波信号作为输入信号,输入信号进入卷积层后需要被激活函数进行激活处理,接着通过卷积层的卷积核对输入信号进行卷积操作并提取特征,不同数量和步长的卷积核可以提取不同的特征。池化层对卷积层的结果进行降采样,使得后续的运算复杂程度降低。池化层分为最大池化层和平均池化层,二者的选择需要根据具体情况去分析,本文采用的是最大池化层。需要说明的是,在卷积操作时可以通过控制步长(stride)降低后续的复杂度,同样地在池化操作时也可以通过控制池化核数目和步长来降低运算复杂度。当进行完数次卷积池化操作后,结果被连接到全连接层进行展开,通常在全连接层之前会有 1 个 Dropout 层,目的是防止在训练时过拟合。最后在全连接层使用 Softmax 分类器进行分类,进而完成全部的训练。本文使用随机森林代替 Softmax 进行分类,可以做到有监督的训练和无监督的识别。

前向传播时,卷积层和卷积层之间的输出可以表示为:

$$x_j^l = f(\sum_{i=1}^M k_i^{l-1} * \omega_{ij}^l + b_j^i)$$
 (17)

其中, k 是卷积核, j 是卷积核数目, M 是上一层输入的通道数, b 是与内核对应的偏置 bias, f 是激活函数, $*$ 为卷积算子, l 为当前层数。

假设最后一个池化层为 $(l-1)$ 层,则输出为:

$$y_j^l = f(\omega^{l-1} \cdot \theta^{l-1} + b^{l-1})$$
 (18)

其中, ω 是权值, b 是偏置。

而神经网络的参数需要用到损失函数进行优化,本文采用的损失函数为交叉熵函数,其形式如式(19)所示,其中 $e^{f_{yi}}$ 是输入指数函数, $f_{yi}=y_j^l$, J_i 是损失函数。

$$J_i = -\log(e^{f_{yi}} / \sum_j e^{f_j})$$

(19)

当执行完最后一个池化层操作时,将输出连接在Dropout层,目的是进一步减少过拟合的可能性。执行该操作时需要设置一个分数值,其范围为[0,1],本文设置为0.5,因此50%的参数将会被抛弃。同时,更少的神经元也增加了各个神经元之间的独立性,减少了相互之间的影响,因此网络对数据中较小的变化变得不敏感。传统的网络结构分类器通常为Softmax,其原理是依据损失函数(loss function)的条件概率进行分类,通过特征属于某一类的概率大小来判别其归属,从而实现分类,本文将分类器替换为随机森林,1D-CNN的网络参数如表4所示。

表 4 1D-CNN 参数
Table 4 1D-CNN parameters

参数名称	参数个数	参数名称	参数个数
卷积层 1	16	池化层 4	128
池化层 1	16	卷积层 5	128
卷积层 2	64	池化层 5	128
池化层 2	64	优化器	Adam
卷积层 3	128	学习率 α	0.01
池化层 3	128	批量	128
卷积层 4	128	Dropout	0.5

3.2 随机森林分类器

随机森林是由一组决策树组成的分类器,具有成熟、可靠、能够对多类数据进行分类的特点。其分类原理是依据决策树投票,依据票数的高低对输入样本进行分类。算法原理如图 11 所示,将原始数据(即 CNN 提取的特征)按照一定的比例随机生成测试集和训练集,对训练集按照 bootstrap 方法抽样构成训练子集,将训练子集送入到每一棵决策树进行训练,将训练好的模型保存好,用测试集对模型进行测试分类。最终由所有决策树综合投票,由票数的多少决定输入向量的最终类标签。

随机森林的精度在现有算法中是最高的,对于大数据量能够保持高效的性能。设一系列决策树 $h_1(x)$, $h_2(x),\cdots,h_n(x)$,构成森林和两个随机向量 $\mathbf{X},\mathbf{Y}$ 。

定义边缘函数式(20):

$$mg(\mathbf{X},\mathbf{Y}) = av_n(I(h_n(\mathbf{X})=\mathbf{Y})) - \max_{j \neq Y} av_n(I(h_n(\mathbf{X})=j))$$

(20)

其中, $I(\cdot)$ 为示性函数; $\mathbf{Y}$ 为正确的分类向量, j 为不正确的分类向量, $av_n(\cdot)$ 表示取平均。边缘函数表示了分类正确的平均得票数超过分类为其他任何类别的平均投票数的程度,边缘函数越大,分类器置信度越高。那




图 11 随机森林执行过程
Fig. 11 Random forest execution process

么泛化误差可以定义为式(21):

$$PE^* = P_{\mathbf{X},\mathbf{Y}}(mg(\mathbf{X},\mathbf{Y}) < 0)$$

(21)

其中, $P_{\mathbf{X},\mathbf{Y}}$ 的下标 $\mathbf{X},\mathbf{Y}$ 表明了概率的定义空间,那么随机森林边缘函数为式(22):

$$mr(\mathbf{X},\mathbf{Y}) = P(h_n(\mathbf{X})=\mathbf{Y}) - \max_{\substack{j \neq Y \\ j=1}}^c P(h_n(K)=j)$$

(22)

其中, $P(h_n(\mathbf{X})=\mathbf{Y})$ 为判断正确的分类概率, $\max_{\substack{j \neq Y \\ j=1}}^c P(h_n(K)=j)$ 为判断错误的其他分类的概率最大值。

随机森林算法的分类准确率定义为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

(23)

其中, TP 为正确的肯定, TN 为正确的否定, FP 为错误的肯定, FN 为错误的否定。依据决策树投票的最高分数就可以完成对 CNN 提取的钢板缺陷特征的训练和分类。

4 实验结果

将网络提取的回波信号特征送入到随机森林分类器进行训练,并将1400组数据按照9:1的比例进行训练和检测。实验结果如图12所示,本章的模型对于缺陷的识别准确率为85.71%(120/140),图13为识别的每一类的稀疏矩阵,从图中可以看出对“无缺陷”情况的识别效果最好。

4.1 不同分类器的对比

为了验证随机森林是否优于Softmax,用相同的数据进行实验。如图14所示,与本文的模型相比,Softmax的准确率为84.28%(118/140),低于本文的模型,说明随




图 12 1D-CNN-RF 实验结果

Fig. 12 Experimental results of 1D-CNN-RF




图 13 识别的稀疏矩阵

Fig. 13 Identified sparse matrix

机森林的精度高于 Softmax,证实了本文所用分类器的正确性和有效性。

4.2 有无变分模态分解(VMD)的对比

为了验证 VMD 对信号的分解和重构是否能够提高精度,将未进行 VMD 分解的信号作为对照组进行实验,实验结果如图 15 所示,没有经过 VMD 操作的模型识别准确率为 83.57% (117/140),低于经过 VMD 操作的模型结果,实验证明了 VMD 的有效性。

4.3 几种方法的对比

为了与其他方法对比实验效果,对文献[8]和[4]的方法用本文实验数据进行复现。文献[8]将缺陷回波信号进行经验模态分解,其次将前 6 个本征模态函数保留并对每一个本征模态函数提取特征,然后对所有特征值进行主成分分析以实现特征降维。取前 8 维数据作为最终的特征值,最后将特征值送入支持向量机进行训练和




图 14 Softmax 分类器的结果

Fig. 14 Results of Softmax classifier




图 15 Without-VMD 的分类结果

Fig. 15 Classification results of Without-VMD

验证。为保证实验结果的可对比性,数据比例划分与本文一致。文献[4]的方法为 WPT+BP 神经网络模型:首先对回波信号进行小波包变换,接着提取分解信号的特征值,最后将特征值送入 BP 神经网络进行训练和分类。同理,训练和验证的数据比例与本文一致。

图 16 和表 5 为 3 种方法的实验结果,由表得 WPT-BPNN 方法误差个数最多。在相同的实验数据下,本文方法的准确率比 EMD-PCA-SVM 模型高 12.14%,以此验证了本文的优化是成功的。相较于 WPT-BPNN 方法,本文方法识别的准确率提高了 14.29%。

表 5 3 种方法识别结果对比

Table 5 Comparison of identification results of the three methods

分类器	来源	准确率
1D-CNN-RF	本文	85.71% (120/140)
EMD-PCA-SVM	文献[8]	73.57% (103/140)
WPT-BPNN	文献[4]	71.42% (100/140)




图 16 3 种模型的识别结果

Fig. 16 Recognition results of the three models




图 18 现场实验结果

Fig. 18 Field experimental results

4.4 现场实验

为验证本模型的实际检测效果,在天然气站场和抢险维修中心对带压天然气管道以及由带压、被淘汰的管道制成的储罐进行检测,图 17 为检测的现场。其中天然气站场的在役管道无缺陷,被淘汰的管道有人工缺陷和自然腐蚀缺陷,但是腐蚀缺陷已被人工除锈只剩不规则的缺陷。实验共获取 38 组超声波回波数据,其中 20 组为无缺陷(天然气管道和储罐),18 组为储罐的人造缺陷(包含了圆柱体缺陷、圆锥体缺陷和不规则缺陷)。按照前文方法,首先将原始信号去冗余保留 7 个回波信号,接着对信号用 coif2 小波基函数进行去噪处理,然后将信号 3 层 VMD 分解和重构,最后将重构信号代入 1D-CNN-RF 模型中,实验结果如图 18 示,现场实验准确率为 71.05%,结果表明,用本文的方法可以在现场进行实验并识别天然气钢制管道缺陷的类型。




图 17 现场实验

Fig. 17 Field experiment

5 结 论

本文针对天然气钢制管道腐蚀缺陷信号,提出了一种基于 VMD-1D-CNN-RF 的缺陷识别方法,对腐蚀缺陷进行特征提取和特征分类。特征提取的对象是超声回波信号,通过 VMD 对缺陷信号分解和重构,用 1D-CNN 对重构后的信号进行特征提取,最后用随机森林对特征进行分类识别。实验结果显示,本文提出的方法对人造缺

陷的识别准确率为 85.71%,相较于其他方法,识别准确率得到了提高。进一步的现场实验表明,本文方法对天然气站场和抢险维修中心现场的管道缺陷检测准确率为 71.05%,验证了本文提出的 VMD-1D-CNN-RF 模型可以快速有效地识别腐蚀缺陷,为天然气钢质管道的检修提供了可靠的技术支持。深度学习的框架往往需要大量的数据进行实验,为此后续也将结合小样本检测方法并结合回波特征进行理论分析和研究。

参考文献

- [1] 宋小春,黄松岭,赵伟. 天然气长输管道裂纹的无损检测方法[J]. 天然气工业,2006(7):103-106,160.
SONG X CH, HUANG S L, ZHAO W. Nondestructive testing method for cracks in long-distance natural gas pipelines [J]. Natural Gas Industry, 2006(7): 103-106,160.
- [2] 焦敬品,成全,刘德宇,等. 基于超声检测的储罐底板腐蚀等级评价方法研究[J]. 中国特种设备安全,2017,33(8):29-34.
JIAO J P, CHENG Q, LIU D Y, et al. Research on corrosion grade evaluation method of storage tank floor based on ultrasonic testing [J]. China Special Equipment Safety, 2017, 33(8): 29-34.
- [3] CHELLAPPA R, WILSON C-L, SIROHEY S. Human and machine recognition of faces: A survey [J]. Proceedings of the IEEE, 1995, 83(5): 705-741.
- [4] 徐蒋明,柯黎明. 摩擦焊焊缝缺陷超声检测信号特征分析与神经网络模式识别[J]. 核动力工程,2020,41(1):163-166.
XU J M, KE L M. Signal feature analysis and neural network pattern recognition of ultrasonic detection of friction stir weld defects [J]. Nuclear Power Engineering, 2020, 41(1): 163-166.

- [5] 施成龙, 师芳芳, 张碧星. 利用深度神经网络和小波包变换进行缺陷类型分析[J]. 声学学报, 2016, 41(4): 499-506.
SHI CH L, SHI F F, ZHANG B X. Defect type analysis using deep neural network and wavelet packet transform [J]. Chinese Journal of Acoustics, 2016, 41(4): 499-506.
- [6] LEGENDRE S, MASSICOTTE D, GOYETTE J, et al. Neural classification of Lamb wave ultrasonic weld testing signals using wavelet coefficients[J]. IEEE Transactions on Instrumentation and Measurement, 2001, 50(3): 672-678.
- [7] 罗来齐. 管道缺陷检测与识别方法研究与实现[D]. 镇江: 江苏大学, 2016.
LUO L Q. Research and implementation of pipeline defect detection and identification method [D]. Zhenjiang: Jiangsu University, 2016.
- [8] 唐东林, 魏子兵, 潘峰, 等. 基于 PCA 和 SVM 的管道腐蚀超声内检测[J]. 传感技术学报, 2018, 31(7): 1040-1045.
TANG D L, WEI Z B, PAN F, et al. Ultrasonic internal detection of pipeline corrosion based on PCA and SVM [J]. Journal of Sensing Technology, 2018, 31(7): 1040-1045.
- [9] RABAH B, BENKEDJOUH T, HABBOUCHE H, et al. A hybrid CNN-BiLSTM approach-based variational mode decomposition for tool wear monitoring [J]. The International Journal of Advanced Manufacturing Technology, 2022, 119(5): 3803-3817.
- [10] 车畅畅, 王华伟, 倪晓梅, 等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测[J]. 机械工程学报, 2021, 57(14): 304-312.
CHE CH CH, WANG H W, NI X M, et al. Remaining life prediction of aero-engine based on 1D-CNN and Bi-LSTM [J]. Chinese Journal of Mechanical Engineering, 2021, 57(14): 304-312.
- [11] 汪海晋, 尹宗宇, 柯臻铮, 等. 基于一维卷积神经网络的螺旋铣刀具磨损监测[J]. 浙江大学学报(工学版), 2020, 54(5): 931-939.
WANG H J, YIN Z Y, KE ZH ZH, et al. Wear monitoring of helical milling tools based on one-dimensional convolutional neural network [J]. Journal of Zhejiang University (Engineering Science), 2020, 54(5): 931-939.
- [12] 赵敬娇, 赵志宏, 杨绍普. 基于残差连接和 1D-CNN 的滚动轴承故障诊断研究[J]. 振动与冲击, 2021, 40(10): 1-6.
ZHAO J J, ZHAN ZH H, YANG SH P. Research on fault diagnosis of rolling bearing based on residual connection and 1D-CNN [J]. Vibration and Shock, 2021, 40(10): 1-6.
- [13] LUO S Y, MA X Q, XU J, et al. Deep learning based monitoring of spatter behavior by the acoustic signal in selective laser melting [J]. Sensors, 2021, 21(21): 7179.
- [14] PANDEY P, AKSHAY R, MIRA M. Explainable 1-D convolutional neural network for damage detection using Lamb wave [J]. Mechanical Systems and Signal Processing, 2022, 164: 108220.
- [15] WIJESINGHE S. Time series forecasting: Analysis of LSTM neural networks to predict exchange rates of currencies[J]. Instrumentation, 2020, 7(4): 25.
- [16] 邓勇, 曹敏, 赖治屹. 基于深度学习的天然气管道气体压力超声检测模式识别方法[J]. 电子测量与仪器学报, 2021, 35(10): 176-183.
DENF Y, CAO M, LAI ZH Y. Pattern recognition method for ultrasonic detection of gas pressure in natural gas pipeline based on deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 176-183.
- [17] 刘金海, 付明芮, 唐建华. 基于漏磁内检测的缺陷识别方法[J]. 仪器仪表学报, 2016, 37(11): 2572-2581.
LIU J H, FU M R, TANG J H. Defect recognition method based on magnetic flux leakage internal detection [J]. Chinese Journal of Scientific Instrument, 2016, 37(11): 2572-2581.
- [18] JING L, XU G C, REN L, et al. Defect intelligent identification in resistance spot welding ultrasonic detection based on wavelet packet and neural network [J]. The International Journal of Advanced Manufacturing Technology, 2017, 90(9-12): 2581-2588.
- [19] ZHANG Z, PAN H, WANG X Y, et al. Machine learning-enriched lamb wave approaches for automated damage detection[J]. Sensors, 2020, 20(6): 1790.
- [20] RAMÍREZ A R, MASON J S D, PEARSON N. Experimental study to differentiate between top and bottom defects for MFL tank floor inspections[J]. NDT & E International, 2009, 42(1): 16-21.
- [21] 林远龙, 陈虎, 祝金丹. 常压储罐底板腐蚀状况检测与安全评估方法[J]. 设备管理与维修, 2010(11): 48-50.
- [22] LIN Y L, CHEN H, ZHU J D. Corrosion condition detection and safety assessment method of atmospheric pressure storage tank bottom plate [J]. Equipment Management and Maintenance, 2010(11): 48-50.

characterization: A review[J]. Measurement: Journal of the International Measurement Confederation, 2021, 186:110155.

作者简介



梁海波, 2008 年于西南石油大学获得博士学位, 现为西南石油大学机电工程学院教授, 博导, 主要研究方向为油气井录井、无损检测等。

E-mail: secondbo@126.com

Liang Haibo received his Ph. D. degree from Southwest Petroleum University in 2008. Now he is a professor in College of Mechanical and Electrical Engineering,

Southwest Petroleum University. His main research interests include oil and gas well logging and NDT.



王怡, 2016 年于西南石油大学获得学士学位, 现为西南石油大学机电工程学院硕士研究生, 主要研究方向为无损检测。

E-mail: 2508660993@qq.com

Wang Yi received her B. Sc. degree from Southwest Petroleum University in 2016. Now she is a M. Sc. candidate in College of Mechanical and Electrical Engineering, Southwest Petroleum University. Her main research interest includes NDT.