

DOI: 10.13382/j.jemi.B2104125

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*

邓 勇¹ 曹 敏¹ 赖治屹²

(1. 西南石油大学 机电工程学院 成都 610500; 2. 西南油气田输气管理处 成都 610203)

摘 要:针对天然气管道气体压力超声检测模式识别问题,提出了对原始信号进行预处理去除冗余信息,然后对信号进行变分模态分解(variational modal decomposition, VMD)提取最优本征模态函数(intrinsic model function, IMF)对信号进行重构,接着对处理好的信号进行连续小波变换(continuous wavelet transform, CWT)使其成为高分辨的时频域2维图,最后用深度卷积神经网络(deep convolution neural network, DCNN)对图片进行特征提取并将部分网络输出和支持向量机(support vector machine, SVM)相连实现有监督的学习和训练并用训练好的支持向量机对剩下的数据进行无监督的模式识别。实验表明,VMD-CNN-SVM模型对压力有无的判别准确率为90.66%,相较于其他方法准确率最高。

关键词:深度学习;超声检测;压力识别;卷积神经网络;变分模态分解;支持向量机

中图分类号: TB551; TN06 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Ultrasonic detection pattern recognition method for natural gas pipeline gas pressure based on deep learning

Deng Yong¹ Cao Min¹ Lai Zhiyi²

(1. College of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, China;

2. Gas Transmission Management Office, Southwest Oil and Gas Field Branch, Chengdu 610213, China)

Abstract: In order to solve the problem of pattern recognition of gas pressure detection in natural gas pipeline, the original signal is preprocessed to remove redundant information, and then the signal is decomposed by variational mode decomposition to extract the optimal Intrinsic mode function and reconstruct the signal. Then, the processed signal is transformed into a high-resolution two-dimensional image in time and frequency domain by continuous wavelet transform. Finally, the image is extracted by deep convolution neural network, and the output of part of the network is connected with support vector machine to realize supervised learning and training. The trained support vector machine is used for unsupervised pattern recognition of the remaining data. Experiments show that the accuracy of vmd-cnn-svm is 90.66%, which is the highest compared with other methods.

Keywords: deep learning; ultrasonic detection; pressure identification; convolutional neural network; variational modal decomposition; support vector machine

0 引 言

天然气腐蚀或人为破坏使得在役天然气管道提前结束服役,因此需要进行动火焊接换管作业。由于无法判断管道是否残存气体,贸然动火作业可能会造成更大的安全事故。目前为了解决这个问题,人们的做法通常是

对管道进行压力检测判断管道压力的有无。传统压力检测方法多为介入式检测,这些方法会对管道造成二次伤害,所以非介入式检测成了当前迫切的需要。超声检测是传统的五大无损检测方法之一,其原理是采集超声波回波信号,然后利用信号分析方法对其进行研究,最后特征可以从回波波形图中提取^[1-2]。目前在非介入式压力检测方面有很多的应用^[3-8]。

在超声波测量介质压力的研究中,文献[3]采用直接时间法对小直径管道的介质压力进行了检测。文献[4]采用瑞利波和临界折射纵波,通过测量超声波传播的时间差进而测量压力罐内的压力。文献[5]采用表面波,通过测量超声波时延进而得到薄壁容器内的压力。文献[6]提出了多次时间间隔融合的方法,实现对声波行程时间的精准测量,进而实现相对准确的罐内压力测量。文献[7-8]利用声阻抗特性测量密闭容器内的液体压力。虽然被检对象的介质属性有所不同,但是使用超声测压已经有了良好的开端。这些方法都是直接或者间接测量回波时间差进而测得气体压力,一般需要两个探头其中一个激发一个接收,通过精密的电路和高分辨率的测量时间芯片完成时间差的测量,且对探头的相对安装位置要求较高,暂时不利于工业应用和现场操作。

近年来,随着人工智能的兴起,基于深度学习的超声信号模式识别方法逐渐应用于无损检测领域^[9-13]。文献[10]提出了利用图卷积网络对滚动轴承进行声学判断,基于图论的知识将声音信号转化为图片,在分类精度方面有了明显的提升。文献[11]将原始振动信号使用快速傅里叶变换(FFT)转换成频谱图像,然后输入到卷积神经网络(CNN)进行特征提取和分类。深度学习具有极强的自主学习能力,通过监督学习训练就可以实现无监督的模式识别^[12-13]。为此提出用深度卷积神经网络提取超声信号的特征。在用深度学习框架对超声波进行识别时需要将波形转化为图片,这样可以使得模式识别过程更加高效。回波信号的本质是一种机械波,由于其包含大量的无用信息(如激发信号,高阶回波),为了使得信号在转化为图片时获得高分辨率,需要对信号进行分解和重构保留最有价值的信号。为此提出了先对原始信号进行变分模态分解^[14-15]和重构目的是提高信号的清晰度放大细节。接着用连续小波变换^[16]对处理后的信号进行变换使其成为高分辨的二维时频图,再用深度卷积神经网络对其进行特征提取,最后对大部分特征向量用支持向量机(SVM)^[17-19]进行监督训练,用训练好的SVM对剩余的特征向量进行无监督的识别,通过分类器的输出判断管道内是否含有气体。

1 理论模型

1.1 超声测压模型

图1所示是超声检测模型,超声传感器在电路激发下产生稳定的纵波在管壁传播,反射波被探头接收通过示波器进行采集和存储,然后送到上位机进行处理。天然气管道有保温材料覆盖温度变化很小,损坏管道中的气体处于相对静止状态,综上所述,本文研究的是恒温、静态情况下的气体压力检测。

定义1 界面上反射波声压 p_r 与入射波声压 p_0 之比为声压反射率:

$$r = \frac{p_r}{p_0} = \frac{Z_{gas} - Z_{steel}}{Z_{gas} + Z_{steel}} \quad (1)$$

式中: Z_{gas} 为天然气的声阻抗; Z_{steel} 为管壁的声阻抗。 Z_{gas} 大小和天然气密度有关,因此声压反射率是一个和压力大小有关的变量。

定义2 超声波在介质中传播的基本方程:

$$\rho_0 \frac{\partial c}{\partial t} + \nabla p = 0 \quad (2)$$

式中: ρ_0 是超声波通过介质的密度; c 是波速; p 是声压。波速是固定的则介质密度和声压有关。超声波在传播过程中一部分波反射被探头接收,一部分波和管道内的气体相遇被无限衰减。通过式(1)、(2)可得推论1,压力会引起声压变化进而引起气体声阻抗变化,进而使得声压反射率变化则回波波形变化(幅值衰减等变化)如图2所示无压力和1 MPa压力下的回波波形在外形上有差异,所以通过波形变化可以得出气体压力变化,而提取波形变化因子是一个典型的模式识别问题。由于特征提取是一个复杂的过程,为此本文提出了用深度卷积神经网络对波形的特征进行提取,利用网络自主学习能力不断地提取高级特征,使得这些特征敏感性高、相关性低、区分度大能够更好的表征波形的内在含义。

推论1 气体压力 p_{gas} 计算公式为:

$$p_{gas} \propto f(r, e) \quad (3)$$

式中: r 是声压反射率 e 为影响补偿因子。




图1 超声检测原理

Fig. 1 Principle of ultrasonic detection

1.2 变分模态分解(VMD)方法

VMD是一种自适应、完全非递归的模态变分和信号处理的方法。通过VMD提取能够表征原始信号的本征模态函数,并重构原始信号进而可以得到包含大数原始信号信息且更加简洁平滑的信号。下面介绍VMD方法,首先一个信号可以被表示为:

$$x(t) = A(t) \cos(\varphi t) \quad (4)$$

式中: A 是幅度; φ 是瞬时相位。假设原始信号 $x(t)$ 被分




图 2 不同压力情况下的回波信号

Fig. 2 Echo signals at different pressures

解为个 k 分量, 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与原始信号相等, 则相应的约束变分表达式为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (5)$$

s. t. $\sum_{k=1}^K u_k = f$

式中: 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:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (6)$$

式中: α 为二次惩罚因子, 作用是降低高斯噪声的干扰。对于式子的求解, 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 、 ω_k 和 λ 的表达式如下:

$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (8)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \gamma(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (9)$$

完成上述流程之后就可以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。为了解决过分解寻求最佳的分解层数, 给出一种利用平均瞬时频率对分解的层数进行判断确定分解层数的方法。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。接下来具体阐述这个方法, 首先假设分解的信号为:

$$u(t) = \begin{pmatrix} u(t)_{11} & \cdots & u(t)_{1n} \\ \vdots & \ddots & \vdots \\ u(t)_{k1} & \cdots & u(t)_{kn} \end{pmatrix} \quad (10)$$

式中: $u(t)$ 是原始信号; k 表示分解的层数, 其大小为 $k=1$ -设定的分解层数; n 是信号的长度。对分解的信号进行 Hilbert 变换:

$$H[u_k(t)] = \tilde{u}_k(t) = \pi^{-1} \int_{-\infty}^{\infty} \frac{u_k(\tau)}{t - \tau} d\tau \quad (11)$$

则瞬时频率为:

$$\omega_k(t) = \frac{u_k(t) \tilde{u}'_k(t) - u'_k(t) \tilde{u}_k(t)}{A^2(t)} \quad (12)$$

对瞬时频率求平均值:

$$\bar{\omega}_k(t) = \frac{1}{N} \sum_{i=1}^N \omega_k(t) \quad (13)$$

根据式 (13), 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, 得到重构后的信号。

1.3 连续小波变换

对一个平方可积函数 $f(t) \in L^2(R)$, $L^2(R)$ 为平方可积空间, 对信号 $f(t)$ 进行连续小波变换有^[13]:

$$W_f(a, \tau) = \langle f(t), \varphi_{a,\tau}(t) \rangle = a^{\frac{1}{2}} \int_{-\infty}^{+\infty} f(t) \varphi^* \left(\frac{t - \tau}{a} \right) dt; a > 0 \quad (14)$$

$\varphi(t)$ 需要满足容许条件:

$$C_\varphi = \int_0^{+\infty} \frac{|\hat{\varphi}|^2}{|\omega|} d\omega < \infty \quad (15)$$

式中: $\varphi(t)$ 为母小波; $\varphi_{a,\tau}(t)$ 为连续小波基函数, $\varphi_{a,\tau}(t)$ 是由 $\varphi(t)$ 经过平移和伸缩变换得到的, a 为尺度因子, τ 为平移因子, t 为时间; ω 表示频率; $\hat{\varphi}(t)$ 为 $\varphi(t)$ 的傅里叶变换。将重构后的信号代入式 (14)、(15) 即可求得其连续小波变换的结果。

1.4 CNN 特征提取

深度 CNN 的本质是一个包含多层神经网络的结构, 由输入层、隐藏层、输出层组成, 其中隐含层可以为多层, 每一层包含若干神经元。神经网络的基本组成就是神经元, 神经元之间互相连接构成神经网络而每一个连接都有权重, 神经网络的模型可表示为:

$$\text{output} = f\left(\sum_{j=1}^J \omega_{kj} h_j - b_k\right) \quad (16)$$

式中: output 是每一层的输出; f 是激活函数; ω_{kj} 表示第 k 层的第 j 个权值; h_j 为输入; b_k 为第 k 层的阈值。神经网络的特点就是权值学习, 卷积神经网络的学习采用了误差修正的学习方法, 其基本思想是利用神经元期望输出与实际输出之间的偏差来作为网络连接权值的调整参考标准。网络的误差定义为:

$$E = \sum E_p \quad (17)$$

$$E_p = \frac{1}{2} \sum_{j=1}^m (y_{pj} - o_{pj})^2 \quad (18)$$

式(18)代表网络关于第 P 个样本的误差测量标准。在卷积神经网络结构中, 属于同一个特征面上的所有神经元共享一个权重, 使得卷积神经网络的泛化能力更强。一个卷积神经网络可以由特征提取部分和一个可训练的分类器组成, 本文主要利用卷积神经网络的特征提取部分, 特征分类部分由外接 SVM 组成, 将网络的特征向量输出作为 SVM 的输入。图 3 所示为本文的深度卷积神经网络框架^[9]。利用卷积神经网络的局部强感知力提取高分辨率的二维时频域图特征, 图 3 是原始信号经过 VMD、连续小波变换的效果图。第 1 层是卷积层, 这一层使用 16 个 3×3 核滤波器, 在这一层中保存图像的原始像素值则系数图可以看作是一个 $224 \times 224 \times 3$ 的矩阵(三色通道 RGB), 卷积后图片的维数为 $224 \times 224 \times 16$ 。第 2 层是 Relu 激活函数层。通常随着 CNN 层数的增加, 训练过程的收敛时间也会增加。为了解决这个问题, 在 Relu 层之后引入了批量归一化层。在这一层中, 所有的输入值都将通过使用当前小批量值的均值和方差来归一化。因此训练过程的收敛速度将会更快。学习率设置为 0.1, 以平衡快速收敛和避免过拟合。在池化层使用最大采样方法, 这一层会对 Relu 层操作之后的图片的空间维度执行下采样操作使得图片空间维度变为 $112 \times 112 \times 32$ 。在 6 次周期性卷积-再归一化汇集操作之后, 最后池化层的输出连接到 Dropout 层用于克服过拟合^[20]。为了保证合适的学习效果使得神经网络充分学习, 压差值设置为 0.5。最后完全连接层将计算类别分数, 其大小为 $1 \times 1 \times 4096$, 其中 4096 个值中的每一个对应于类别分数。本文卷积神经网络的输出用于训练 SVM。首先通过监督学习构建 SVM 分类器, 接着用训练好的 SVM 对其余特征进行无监督的识别, 最终将输出转化为两个类别标签, 即无压力和有压力。

2 实验过程和数据

图 4 所示为某天然气站场的试验平台, 通过压力调节阀可实现 $0 \sim 3.5$ MPa 的压力变化量, 间隔为 0.1 MPa,




图 3 CNN 结构

Fig. 3 CNN structure

管道壁厚均匀为 6 mm 材料为钢材, 温度 14.7°C 。实验时, 将具有发射和接收功能的超声探头用辅助夹具固定在管壁上, 目的是排除传统手工检测带来的粗大误差。探头的直径为 20 mm, 中心频率为 2.5 MHz, 激发电压为 300 V。每采集一组数据需要长时间的等待, 当罐内的气体趋于稳定时, 采集回波信号。其中压力为 0 MPa 时(可以通过压力表进行), 视为没有压力, 其余情况均视为有压力。




图 4 实验平台

Fig. 4 Experimental platform

2.1 变分模态分解和重构

图 2 的原始信号包含了激发信号, 因此需要去除掉。以 0 MPa 的回波信号为例, 按照 1.2 节的方法进行最优分解个数的判断。平均瞬时频率结果如图 5 所示, 当分解的个数为两个时出现了明显的转折, 根据前面的推导可以说明此时分解个数已经达到了最优, 当 $K=2$ 时, 分解的效果最好, 其和原始信号的相关系数为 0.945 6, 保留了原始信号中的大量信息。分解: 对原信号进行分解的结果如图 6 所示, 图 6(a) 是 IMF 分量横坐标是时间, 图 6(b) 是频谱图横坐标是频率, 图 6(a1) 和 (b1) 为原始信号, 其余行为 IMF 分量。重构是把小于等于 K 值的最优 IMF 分量进行重构。图 7(a)、(b) 所示为原始信号和

重构之后的信号,相较于原始信号图 7(a),重构后的信号 7(b)更加的简洁平滑。




图 5 基于瞬时频率法的变分模态分解个数
Fig. 5 Number of variational modal decomposition based on instantaneous frequency method




图 6 变分模态分解结果
Fig. 6 Variational modal decomposition results

2.2 原始数据集

按照上述处理流程对原始信号进行截取和分解和重构之后对重构信号进行 CWT 变换结果如图 7(c) 所示。如此反复进行升压和降压实验,并更换测点(壁厚误差±0.05 mm),共得到 650 组数据,其中没有压力的数据为 200 组。随机选取其中 500 组数据进行 SVM 训练,然后利用训练好的 SVM 模型对剩下的 150 组数据进行测试。

需要说明的是对数据进行人工标签,其中有气体的标签为 1,没有气体的标签为 0。




图 7 (a) 原始信号; (b) 重构效果; (c) CWT 变换结果
Fig. 7 (a) Original signal; (b) Reconstruction effect; (c) Results of CWT transformation

3 实验结果

3.1 CNN 特征提取和 SVM 分类效果

把提取到的特征输入到 MATLAB 2018a 版本 APP-Classification 中的 SVM 分类器进行监督训练,其核函数为 Quadratic。训练的结果如图 8(a) 所示,训练的准确率为 94.8%。接着把训练好的模型保存起来,用剩余的数据进行测试。如图 8(b) 所示,预测的准确率为 90.66%。图 9 所示为没有对原始信号进行 VMD 操作的实验结果,其准确率为 84%。实验表明,经过 VMD 重构的信号保存了大部分原始信号的信息且在变换后特征更加清晰;深度卷积神经网络提取的特征是有效的、敏感的且可以通过期望不断地调整学习提取最优特征。

3.2 几种方法的对比

在超声信号处理中,文献[21]提出了 WPT-BPNN 方法提取了 14 个时域和频域特征,为了使得分类方法一致将 WPT-BPNN 方法中的神经网络分类器换成 SVM 分类器。相较于神经网络而言,SVM 在二分类中的效果更好。图 10 所示为 WPT-SVM 方法的预测效果。通过方法对比可知 CNN 提取的高级特征优于 WPT 方法提取的 14 个时频域特征。为了对比 EMD 和 VMD 的分解效果对原始信号进行 EMD 分解提取前 6 个 IMF 函数重构信号。图 11 所示为 EMD-CNN-SVM 方法的预测结果,其准确率为 88.66%。这个结果低于 VMD-CNN-SVM 模型的准确率。因此说明了 VMD 方法在实际使用中可以克服 EMD 方法存在的端点效应等问题,在信号分解方面表现出更优越的性能。




图 8 VMD-CNN-SVM 方法
Fig. 8 VMD-CNN-SVM method




图 9 CNN-SVM 方法
Fig. 9 CNN-SVM method




图 10 WPT-SVM 方法
Fig. 10 WPT-SVM method

4 结论和展望

4.1 结论

表 1 把本文提到的 4 种方法进行了梳理。从表中可

以看出,本文提出的 VMD-CNN-SVM 方法在天然气管道压力有无的判别中准确率最高,相较于 EMD-CNN-SVM、CNN-SVM、WPT-SVM 模型准确率分别提高了 2.00%、6.66%、8.00%。




图 11 EMD-CNN-SVM 方法
Fig. 11 EMD-CNN-SVM method

表 1 不同方法及识别的准确率

Table 1 Accuracy of different methods and recognition

方法	准确率/%
VMD-CNN-SVM	90.66
EMD-CNN-SVM	88.66
CNN-SVM	84.00
WPT-SVM	82.66

4.2 误差来源分析

针对本文的背景误差来源有如下情况:1)壁厚对于回波的影响,由于本实验是壁厚为 6 mm (± 0.05 mm)的天然气管道中进行,下一步将会对壁厚因素进行实验得到更加完善的模型;2)管道污渍和站场噪声对信号的影响,对于噪声影响已经使用了同轴线进行屏蔽,对于管道污渍还需要进一步的考察管道内部情况。

4.3 下一步安排

本文只对压力的有无进行了判断,为了使得这种方法更具有实际的推广意义,未来将在判定管道含有压力的情况下进一步对管道内气体的大小进行量化识别,并且综合各种可能的影响因素对模型进行修正,同时也会考虑对直接时间测量法进行研究,将两个方法的实验结果进行对比和讨论。

参考文献

[1] ZHANG X, AUGEREAU F, LAUX D, et al. Non-destructive testing of paint coatings on steel plates by ultrasonic reflectometry [J]. Journal of Nondestructive Evaluation, 2014, 33(4) : 504-514.

[2] SUGASAWA S, SHIBATA T. Evaluation of elastic constants of antifouling paint film using group delay spectrum method [J]. Japanese Journal of Applied Physics, 2007, 46(7B) : 4583-4588.

[3] WANG D, SONG Z X, WU Y, et al. Ultrasonic wave based pressure measurement in small diameter pipeline [J]. Ultrasonics, 2015, 63:1-6.

[4] LING Z, ZHANG H, ZHOU H. Nondestructive pressure measurement in vessels using rayleigh waves and LCR waves [C]. IEEE Instrumentation and Measurement Technology Conference, 2008:682-686.

[5] ZHANG H J, HE Q, YAN Y. A new nondestructive technique for measuring pressure in vessels by surface waves[J]. Applied Acoustics, 2008, 69(10) : 891-900.

[6] ZHOU H, FAN W, GE X, et al. Pressure sensor based on the time-interval between neighboring longitudinal waves[J]. IEEE Sensors Letters, 2017, 1(6) : 1-4.

[7] GUERS M J, FONTANA C J, ZILISKIS D R, et al. Investigation of noninvasive approaches for pressure measurement [J]. Review of Progress in Quantitative Nondestructive Evaluation, 2007, 26: 1653-1659.

[8] GUERS M J, FONTANA C J, TITTMANN B R. A noninvasive pressure measurement technique and the potential for integrated calibration [J]. Review of Progress in Quantitative Nondestructive Evaluation, 2008, 27: 1500-1504.

[9] YAN Y, LIU D, GAO B, et al. A deep learning-based ultrasonic pattern recognition method for inspecting girth weld cracking of gas pipeline[J]. IEEE Sensors Journal, 2020, 20(14) : 7997-8006.

[10] ZHANG D C, STEWART E, ENTEZAMI M, et al. Intelligent acoustic-based fault diagnosis of roller bearings using a deep graph convolutional network [J]. Measurement, 2020, DOI: 10.1016/j. measurement. 2020. 107585.

[11] CHEN Z, LI C, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks [J]. Shock Vibrat, 2015, DOI: 10.1155/ 2015/390134.

[12] YOUSEFI B, KALHPR D, FERNANEDZ R U, et al. Application of deep learning in infrared non-destructive

- testing [C]. 14th Quantitative InfraRed Thermography Conference, 2018: 1-9.
- [13] REN R, HUNG T, TAN K C. A generic deep-learning-based approach for automated surface inspection [J]. IEEE Transactions on Cybernetics, 2018, 48 (3): 929-940.
- [14] 陈剑, 夏康, 黄凯旋, 等. 基于 VMD 相对能量熵和自适应 ARMA 模型的轴承性能退化趋势动态预警 [J]. 电子测量与仪器学报, 2020, 34(8): 116-123.
- CHEN J, XIA K, HUANG K X, et al. Dynamic early warning of bearing performance degradation trend based on VMD relative energy entropy and adaptive ARMA model [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(8): 116-123.
- [15] HUANG Q Y, XIE L F, YIN G F, et al. Acoustic signal analysis for detecting defects inside an arc magnet using a combination of variational mode decomposition and beetle antennae search [J]. ISA Transactions, 2020, 102: 347-364.
- [16] GUTTMAN L. The Basis for Scalogram Analysis [M]. Indianapolis: Bobbs-Merrill, 1974.
- [17] 洪翠, 杨华锋, 卢国仪, 等. 基于振动信号 SVM 分类的配变故障识别方法 [J]. 仪器仪表学报, 2016, 37(6): 1299-1308.
- HONG C, YANG H F, LU G Y, et al. Fault identification method of distribution and transforming based on SVM classification of vibration signals [J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1299-1308.
- [18] CAI Y, W DE SILVA C, LI B et al. Application of feature extraction through convolution neural networks and SVM classifier for robust grading of apples [J]. Instrumentation, 2019, 6(4): 59-71.
- [19] 宁琦, 耿读艳, 王晨旭, 等. 基于多尺度排列熵及 PSO-SVM 的输电线路故障判别 [J]. 电子测量与仪器学报, 2019, 33(7): 173-180.
- NING Q, GENG D Y, WANG C X, et al. Transmission line fault diagnosis based on multi-scale permutation entropy and PSO-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (7): 173-180.
- [20] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from over-fitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [21] LIU J, XU G, REN L, et al. Defect intelligent identification in resistance spot welding ultrasonic detection based on wavelet packet and neural network [J]. International Journal of Advanced Manufacturing Technology, 2017, 90(9-12): 2581-2588.

作者简介



邓勇, 1994 年于西安交通大学获得学士学位, 1997 年于电子科技大学获得硕士学位, 2012 年于电子科技大学获得博士学位, 现为西南石油大学机电工程学院副教授, 主要研究方向为复杂条件下的无损检测和模式识别。

E-mail: 201231010013@swpu.edu.cn **Deng Yong** received his B.Sc. degree in 1994 from Xi'an Jiaotong University, received his M.Sc. degree in 1997 from University of Electronic Science and Technology of China, received his Ph.D. degree in 2012 from University of Electronic Science and Technology of China, now he is an associate professor in SWPU. His main research interest includes NDT and pattern recognition.



曹敏, 2019 于西南石油大学获得学士学位, 现为西南石油大学硕士研究生, 主要研究方向为超声波无损检测。

E-mail: 1040362914@qq.com

Cao Min received B.Sc. from Southwest Petroleum University in 2019. Now he is a M.Sc. candidate at Southwest Petroleum University. His main research interest includes ultrasonic non-destructive testing.