

基于声学特征优选 ELM-RF 模型的 气体泄漏孔径评估*

何 栋, 程中文, 袁懋诞, 曾吕明, 纪轩荣

(广东工业大学精密电子制造技术与装备国家重点实验室 广州, 510006)

摘要 针对传统方法对压力容器气体泄漏声学特征提取不足、检测准确率低及结果不够稳定的问题, 为了实现真实背景噪声下压力容器泄漏孔径大小评估, 提出一种基于随机森林(random forest, 简称 RF) 声学特征优选并结合 RF 框架和极限学习机(extreme learning machine, 简称 ELM) 的容器泄漏孔径评估方法。首先, 提取不同气压大小、不同采样位置下直径在 0.1~1.5 mm 之间泄漏孔超声信号的时域、频域特征值及梅尔倒谱系数(Mel frequency cepstral coefficients, 简称 MFCC); 其次, 利用 RF 进行特征重要度排序并提取 172 个优选特征值; 最后, 将 ELM 作为 RF 的基学习器以提高 ELM 分类性能, 实现亚毫米级别泄漏孔径大小的分类。结果表明: 提出的方法能够有效评估泄漏程度且结果稳定, 分类准确率达 85.79%; 相比于 ELM 算法准确率提升 2.65%, 准确率方差下降 0.46, 为压力容器气体泄漏检测领域提供一种有效的检测手段。

关键词 压力容器安全; 泄漏孔检测; 声学特征; 极限学习机; 随机森林

中图分类号 TH49; TB52

0 引言

压力容器被广泛应用于石油、化工和航空航天工业中^[1-2], 容器内一般填充有害气体或液化气体^[3-5], 在制造、保管、运输及使用过程中极有可能发生泄漏, 不仅造成能源损失, 而且危及人民生命安全。由于压力容器的泄漏具有隐蔽性, 因此及时准确地发现泄漏并对泄漏严重程度进行评估, 对减少和防止因压力容器泄漏而引发的安全事故具有重要意义^[6-7]。

泄漏检测主要是基于气体湍流和涡声理论, 当气体从高压区流向低压区时, 气体流速陡增, 泄漏点附近的气体流动可能变为湍流。由于气体湍流产生的细小涡流和扰动会产生噪声振动, 因此检测这些波动可以作为一种有效的泄漏检测方法。泄漏检测的主要过程包含使用合适的传感器对信号进行采集, 对采集到的信号进行特征提取以及使用机器学习算法进行泄漏识别。在超声信号特征提取方面, 常用的方法有峰值检测、时域及频域特征提取、自相关函数和互相关函数、傅里叶变换、小波变换以及经

验模态分解等^[8]。在提取特征后, 并非所有的特征信息都对分类任务具有同等重要性, 需要筛选出重要特征信息。目前, 广泛采用的特征选择方法有随机森林^[9]、主成分分析法^[10]等。在泄漏分类识别领域, 常用的方法包括反向传播(back propagation, 简称 BP)神经网络、支持向量机及卷积神经网络等。例如, 将支持向量机用于泄漏检测^[11-12], 基于预训练的 AlexNet 网络改编的卷积神经网络模型^[13]用于聚氯乙烯板的泄漏检测, 使用 4 层深度神经网络^[14]检测管道泄漏的声音, 识别结果均比普通神经网络获得更高的准确率。将稀疏自动编码器网络与改进支持向量机相结合, 可以提高泄漏检测的准确性^[15]。然而, 上述模型对噪声敏感, 在强背景噪声下识别泄漏的结果不够稳定。

文献[16-18]提出的极限学习机, 其训练过程快速且具有较强的泛化能力。相比于广义回归神经网络(generalized regression neural network, 简称 GRNN)和径向基函数神经网络(radial basis function neural network, 简称 RBFNN), 仅需一次训练即可。然而, ELM 的性能会因为权重和阈值的随机初始化及数据质量而波动, 这在一定程度上影响了分类稳定性。

* 国家自然科学基金资助项目(U2133213, 51975131); 广东省自然科学基金资助项目(2023A1515011620, 2022A1515240040)

收稿日期: 2024-01-22; 修回日期: 2024-03-22

笔者提出一种结合RF和ELM的压力容器气体泄漏检测方法。首先,使用RF进行特征优选以剔除冗余特征;其次,替换RF中的决策树为ELM;最后,结合RF的特征随机采样和ELM的快速训练优势,构建了一个新框架对压力容器泄漏孔孔径的大小进行分类,进而对压力容器气体泄漏程度进行评估。实验结果表明,在强背景噪声下,经过特征优选且改进后的集成ELM模型可以有效提高压力容

器气体泄漏孔孔径大小的分类准确率及稳定性。

1 压力容器气体泄漏检测分类框架

笔者提出的压力容器气体泄漏检测与分类框架如图1所示。该框架由两部分组成:①泄漏超声信号特征优选;②用于泄漏检测和分类的ELM-RF算法。




图1 压力容器气体泄漏检测与分类框架

Fig.1 Pressure vessel gas leak detection and classification framework

在泄漏超声信号特征优选阶段,对采集到的超声信号进行预处理,包括预加重、分帧和加窗。预加重可以增强信号高频部分信息,提取预处理后信号的MFCC、时域特征及频域特征,使用RF剔除冗余特征形成优选声学特征数据集。在泄漏检测与分类阶段,基于归一化特征数据集,使用ELM-RF算法进行泄漏孔径大小分类。

1.1 声学特征提取

压力容器正常运行时,由于背景噪声的影响,声学信号表现为小的随机波动^[19]。当压力容器发生泄漏时,声学信号的振幅会随着泄漏孔径的大小而发生变化。MFCC是一种基于人类听觉模型的特征^[20],与频率有非线性关系,其独特的非线性变换特性比其他方法的抗噪声能力更强,在声学故障信号的特征提取方面具有良好的应用前景。MFCC特征的提取方法如下:首先,将时域信号通过离散傅里叶变换转换到频域,计算能量谱;其次,将能量谱

与梅尔尺度的三角滤波器组进行卷积,并对三角滤波器的输出结果进行离散余弦变换;最后,选择前 L 阶系数作为该信号的MFCC。

MFCC的计算公式为

$$C(n) = \sum_{m=0}^{N-1} s(m) \cos\left(\frac{\pi n(m-0.5)}{M}\right) \quad (n=1, 2, \dots, L) \quad (1)$$

其中: $C(n)$ 为第 n 个MFCC; L 为MFCC系数的阶数,通常取12~16; $s(m)$ 为信号的对数功率谱; M 为三角滤波器个数。

分别提取压力容器气体泄漏超声信号的时域特征、频域特征及MFCC共同构成特征集。时域特征是描述信号特征的一个指标,例如:平均值反映信号的整体水平或直流分量;方差和标准差反映信号波动程度;波峰因子反映信号振幅变化;脉冲因子反映泄漏信号对特性的影响;峰值和峰值因子反映信号的振幅分布。所提取的时域特征有最大值、最小值、平均值、峰峰值、整流平均值、有效值、峰值、方

差、标准差、峭度、偏度因子、均方根、波形因子、峰值因子、脉冲因子及裕度因子。研究可知,泄漏信号在频域上是一种无特定标志的宽频噪声信号。所提取的频域特征有重心频率、均方频率、均方根频率、频率方差、频率标准差及相对功率谱熵^[21]。

1.2 RF 特征优选

压力容器气体泄漏产生的超声信号中提取的多域特征集能够揭示原始信号的特征信息,但需移除其中的冗余特征信息,以优化分类和计算效率。RF 是一种具有高鲁棒性且适用于处理大量特征数据的集成学习方法,可用于分类、回归及特征选择。随机

森林流程图如图 2 所示。其使用 Bagging 方法^[22]创建多棵决策树,最终通过投票或平均法形成稳定准确的模型。在 RF 中,平均精度下降(mean decrease accuracy,简称 MDA)和平均不纯度减少(mean decrease impurity,简称 MDI)是 2 种常用的特征重要性评估指标。由于 MDA 对数据的随机波动更加稳健,且更可能识别出对模型泛化能力贡献大的特征,因此选择 MDA 来评估特征的重要性^[23]。在衡量每个特征对于模型性能的影响程度时,高 MDA 值的特征通常被认为是更重要的,可以用于识别关键特征,以改善模型的性能并减少过度拟合的风险。




图 2 随机森林流程图

Fig.2 RF flow chart

以压力容器气体泄漏检测为例,考虑 N 个泄漏声音信号样本 $(XL_j, y_j), j = 1, 2, \dots, N$, 其中: XL_j 为泄漏声音信号的特征; y_j 为泄漏孔径大小类别。在使用 RF 算法评估泄漏声音信号特征 XL_j 的重要性时,首先,将每颗决策树 i 作为起点计算袋外数据误差 OOB^{error_i} , 对模型在未使用样本情况下的性能误差进行衡量,将袋外数据中的特征值进行重排,同时保持其他特征不变,生成一组新的袋外数据子集;其次,计算这组新的袋外数据误差 $OOB^{error'_i}$, 其反映了通过改变特定特征对模型性能的影响。通过将 2 次袋外误差相减可以得到泄漏声音信号特征 XL_j 在第 i 颗决策树中的 MDA 值,其计算公式为

$$MDA_i(XL_j) = OOB^{error'_i} - OOB^{error_i} \quad (2)$$

通过计算 RF 中泄漏声音信号特征在每颗决策树中的 MDA 值并求平均值,可以得到 XL_j 的特征重

要度,即

$$MDA(XL_j) = \frac{1}{N} \sum_{i=1}^N MDA_i(XL_j) \quad (3)$$

在压力容器气体泄漏孔径大小的分类中,利用 RF 算法来计算特征的 MDA 值并进行排序,可以筛选出重要特征,从而提高泄漏孔径大小分类的准确率。

2 ELM-RF 压力容器气体泄漏检测模型

2.1 ELM 算法原理

在 ELM 结构中,设有 n 个输入层神经元, l 个单隐藏层神经元, m 个输出层神经元, ω 为输入层与隐藏层之间的连接权重,隐藏层偏置为 b ,隐藏层与输

出层神经元之间的连接权值为 β 。

对于给定的 N 个样本 $(x_i, y_i), i=1, 2, \dots, N$, 其中: $x_i=(x_{i1}, x_{i2}, \dots, x_{in})^T \in R^n$, 为输入数据; $y_i=(y_{i1}, y_{i2}, \dots, y_{im})^T \in R^m$, 为期望输出数据。设激活函数为 $g(\bullet)$, 则ELM模型函数可表示为

$$y_j = \sum_{i=1}^l \beta_i g_i(x_j) = \sum_{i=1}^l \beta_i g(\omega_i x_j + b_i) \quad (4)$$

($j=1, 2, \dots, N; N=h(x)\beta_j$)

式(4)可表示为 $H\beta = Q^T$, 其中: H 为隐藏层神经元的输出矩阵; Q^T 为ELM输出矩阵 Q 的转置, 即

$$H(\omega_1, \omega_2, \dots, \omega_l, b_1, b_2, \dots, b_l, x_1, x_2, \dots, x_N) = \begin{bmatrix} g(\omega_1 x_1 + b_1) & g(\omega_2 x_1 + b_2) & \dots & g(\omega_l x_1 + b_l) \\ g(\omega_1 x_2 + b_1) & g(\omega_2 x_2 + b_2) & \dots & g(\omega_l x_2 + b_l) \\ \vdots & \vdots & & \vdots \\ g(\omega_1 x_N + b_1) & g(\omega_2 x_N + b_2) & \dots & g(\omega_l x_N + b_l) \end{bmatrix}_{N \times l} \quad (5)$$

使用最小二乘法求解 $\min \|H\beta - Q^T\|$, 可得到

隐藏层与输出层的连接权值 β , 即

$$\hat{\beta} = H^+ Q \quad (6)$$

其中: H^+ 为隐藏层输出矩阵 H 的 Moore-Penrose 广义逆。

2.2 ELM-RF模型

数据变换会对随机森林中的决策树建立造成影响, 随机森林算法具有广泛的适用性。在ELM模型中, 不同的数据集受到随机初始化输入层与隐藏层之间的连接权重矩阵和隐藏层神经元的偏置向量的影响, 将计算出不同的输出权值, 可以得到多个具有差异性的ELM模型。因此, 可将ELM作为随机森林中的基学习器, 并将随机森林中可重复随机采样的采样方法应用于ELM输入层神经元中, 利用ELM高效的训练过程, 整体集成框架采用随机森林框架, 即通过构建多棵树并进行投票来减少过拟合, 提高模型的泛化能力。其中, ELM模型负责获取数据的复杂非线性关系, 而随机森林则提供了一个多样化的集成框架。ELM-RF算法流程如图3所示。




图3 ELM-RF算法流程图

Fig.3 Flowchart of ELM-RF algorithm

对于给定的 N 个压力容器气体泄漏声音信号训练样本 (x_i, y_i) , 其中: $x_i=[x_{i1}, x_{i2}, \dots, x_{im}]^T$, 为压力容器气体泄漏声音信号的多域声学特征数据; $y_i=[y_1, y_2, \dots, y_R]^T$, 为样本对应的压力容器泄漏孔径大小, 共有 R 个孔径大小; m 为每个样本声学特征数据的特征数。采用随机森林框架并将ELM作为基分类器建立ELM-RF模型, 其步骤如下:

- 1) 对训练样本集进行可重复随机采样, 得到 L 个样本子集, 每个样本子集中的样本数为 N ;
- 2) 将 L 个样本子集输入 L 个ELM基分类器中, 每个基分类器随机选择 P 个特征进行训练;
- 3) 将训练完毕的 L 个ELM基分类器集成为一

个强分类器, 将测试集样本输入每个ELM基分类器, 得到 $Z(Z \leq R)$ 个分类结果, 对 Z 个分类结果使用取众数的投票策略得到最终的分分类结果。

在ELM-RF集成框架中, 不同的随机初始化和数据子集确保了ELM网络的多样性, 同时随机森林为这些多样化的模型提供框架来提升和稳定整个系统的性能, 降低模型方差并增强模型对于不同数据分布的适应性。

3 实验与分析

3.1 实验系统搭建

所搭建的气体泄漏声波信号数据采集系统如图4

所示,实验环境噪声为65 dB。其中:1为气源,是提供一定压力的气体;2为压力容器,其容积为5 L,所承受压力 ≤ 1.25 MPa;3为带有压强刻度的调压阀;4为使用激光打孔后带有不同尺寸泄漏圆孔的堵头,其模拟泄漏孔孔径的大小分别为1.5、1.2、0.8、0.6、0.5、0.4、0.3、0.2和0.1 mm,用于模拟不同程度的气体泄漏故障;5为涵盖了声和超声频段的无膜光学麦克风,其带有可调截止频率及放大倍数的宽频带,可接收的信号频率范围为10 Hz~1 MHz;6为放大器;7为示波器,用于记录采集的数据。




图4 气体泄漏声波信号数据采集系统

Fig.4 Gas leak acoustic signal data collection system

3.2 实验条件设置

由于气体泄漏所产生的超声信号的频率主要集中在20 kHz~100 kHz之间^[24],因此选用宽频带的无膜光学麦克风探头采集泄漏声波信号。探头的截止频率设为10 kHz,采样频率设为200 kHz,以保证采样信号的质量。为改变声音信号的特征,将气压大小分别设置为0.35、0.3、0.25和0.2 MPa。检测位置示意图如图5所示。压力容器与传感器的初始距离为500 mm,如图5中B位置所示。为增加检测模型的适用性,改变传感器接收信号的距离和角度,将接收信号的传感器在前后左右各100 mm进行平移,如图5中A、C、D和E位置所示。由于0.4~0.1 mm的泄漏孔产生的声音信号较微弱,将无膜光学麦克风自带信号放大器的放大倍数设为20 dB,另外加上60 dB信号放大器进行信号放大处理。对于每个泄漏孔,在每种大小气压和位置上采集20组数据,共计3 600组数据,每组信号包含100 000个点,时间为500 ms。为加强噪声对信号的影响,增强模型的广泛性,将气压大小为0.3 MPa的数据加上信噪比为10 dB的高斯白噪声额外加入到数据集

中,总共为4 500组数据,其中每个泄漏孔包含500组数据。随机选取总样本数据的80%作为训练集,其余数据作为测试集。




图5 检测位置示意图(单位:mm)

Fig.5 Detection position diagram(unit:mm)

3.3 特征提取与优选

在信号预处理过程中,预加重系数为0.97,将信号分为9帧,在每帧上根据第1节所提特征提取方法提取各样本的时域特征16个、频域特征6个及前13阶MFCC系数,在提取MFCC系数过程中梅尔滤波器数量为20,总共计算得到315个特征值。在特征优选阶段,使用RF算法计算特征集中每个特征的MDA值200次,将其结果的平均值作为该特征最终重要度结果。RF200次特征重要度排序结果如图6所示。




图6 RF200次特征重要度排序结果

Fig.6 RF200 feature importance ranking results

根据排序后的结果,将特征值逐个递增地输入到ELM模型中进行泄漏孔径大小的分类。优选特征集中特征个数对分类准确率的影响如图7所示。可见,分类准确率不会持续地随着特征数量的增加而增加,而是在达到一个峰值后趋于稳定甚至下降。这是由于分类模型可能会把这些冗余特征误认为是有用的信息并过度依赖其来做决策,但在未见

过的数据上表现不佳,使得模型泛化能力变弱,对训练数据噪声的敏感度增加。此外,过多的特征数量会增加模型的复杂度,导致计算成本上升,也增加了模型泛化的不确定性^[25]。由图7可知,当特征集中的特征数量达到172个之前,准确率逐渐上升,达到172个时分类准确率最高,随后趋于稳定甚至下降。因此,为减少计算量,选择特征重要度排序后结果的前172个特征作为RF优选后的特征集。




图7 优选特征集中特征个数对分类准确率的影响

Fig.7 Influence of the number of features in the preferred feature set on diagnostic accuracy

为了验证经过RF优选后的特征集能够提高分类准确率,分别将时域特征集、频域特征集、时-频域特征集、多域特征集及RF优选特征集输入到单个ELM分类器中计算200次,取计算结果的平均值作为最终结果。不同特征集200次分类结果如图8所示。




图8 不同特征集200次分类结果


Fig.8 Different feature sets 200 times classification results

由图8可知,相较于多域特征集和单域特征集,RF筛选后的特征集表现出更高的分类准确率。虽然多域特征集提供了更多超声特征信息,但其中部分特征信息冗余甚至无效,使用RF算法提取有效特征并消除无效和冗余特征,可以提升对压力容器气体泄漏孔径大小的分类准确率。

3.4 ELM-RF模型分类结果分析


在进行泄漏孔孔径大小的分类时,为验证所提出ELM-RF集成学习模型对提高ELM模型效率及稳定性的效果,将经RF算法特征优选后的特征集分别输入ELM模型与ELM-RF模型中。鉴于样本中输入特征集的维度与模拟泄漏孔径大小类别的数目,ELM的网络结构为172-855-9。其中:172为经RF特征优选得到的特征,即ELM网络的输入层神经元数目为172;9为ELM输出的9个模拟泄漏孔分类结果;855为ELM隐藏层神经元个数。ELM激活函数为“sigmoid”,随机森林框架中ELM基学习器个数为50,隐藏神经元个数为770,每个基学习器可重复随机采样的特征数量为13,采用Matlab软件进行仿真。

使用ELM与ELM-RF分别进行200次计算,ELM与ELM-RF分类结果对比如图9所示。由图可知,ELM和ELM-RF的分类准确率平均值分别为84.01%和85.79%,提高了压力容器气体泄漏孔孔径大小分类的准确率。ELM-RF分类结果混淆矩阵如图10所示。由图可知:模型在类别1.5、0.6和0.4上显示出较高的准确率(97.1%,92.4%和91.7%);类别0.2经常与0.1、0.3和0.4发生混淆,0.8与1.2发生混淆,这可能是由于其在特征上的相似性导致的。总体而言,模型的准确率为85.79%。



(a) ELM分类结果

(a) Classification results of ELM



(b) ELM-RF分类结果

(b) Classification results of ELM-RF

图9 ELM与ELM-RF分类结果对比

Fig.9 Comparison of classification results between ELM and ELM-RF




图 10 ELM-RF 分类结果混淆矩阵

Fig.10 Confusion matrix of ELM-RF classification results

为验证所提方法的有效性,将 ELM-RF 分别与 ELM、BP 神经网络的分类结果进行对比,对这 3 种方法都进行了 200 次运行,计算其分类准确率和运行时间的平均结果。各种方法分类性能对比见表 1。其中, BP 神经网络、ELM 和 ELM-RF 分类准确率方差分别为 1.76、1.49 和 1.03。可见,ELM-RF 模型的分类准确率高于单一 ELM 模型,稳定性高于 BP 神经网络及 ELM 模型,且诊断时间大大低于 BP 神经网络。

表 1 各种方法分类性能对比
Tab.1 Comparison of classification performance of various methods

方法	分类准确率 (平均值±方差)	识别时间/s
BP 神经网络	73.69%±1.76	2 021.03
ELM	84.01%±1.49	1.79
ELM-RF	85.79%±1.03	1.81

亚毫米级别孔径的大小在 0.1~0.8 mm 之间,其各种分类方法性能对比见表 2。由表可知:BP 神经网络分类准确率较低且识别时间较长;ELM、ELM-RF 分类准确率相比于毫米级别孔径,分类结果皆提升了 2%;BP 神经网络、ELM 和 ELM-RF 针对亚毫米级别孔径的准确率方差分别为 1.47、1.34

表 2 亚毫米级别孔径的各种方法分类性能对比
Tab.2 Comparison of performance in various methods for sub-millimeter aperture classification

分类方法	分类准确率 (平均值±方差)	识别时间/s
BP 神经网络	79.23%±1.47	1 951.69
ELM	86.16%±1.34	1.57
ELM-RF	87.87%±0.87	1.62

和 0.87,说明所提出方法针对亚毫米级别孔径分类的准确率、稳定性及分类时间仍有较好的表现,且相比于毫米级别泄漏孔的分类准确率提高了 2.20%。结果表明,所提方法能够有效分类压力容器气体泄漏孔径大小,分类结果更加稳定,且分类用时更短。

4 结 论

- 1) 利用 ELM-RF 算法能够对强背景噪声下的压力容器气体泄漏微孔径大小进行有效分类,并对泄漏的严重程度进行评估,分类准确率达到 85.79%。
- 2) 利用 RF 中的 Bagging 算法能够有效剔除冗余特征,将模型分类准确率提高了 2%。
- 3) 利用 ELM-RF 算法进行分类的准确率相比 ELM 算法提高了 2.65%,方差下降了 0.46。

参 考 文 献

[1] GHOSH G, ROSTRON P, GARG R, et al. Hydrogen induced cracking of pipeline and pressure vessel steels: a review[J]. Engineering Fracture Mechanics, 2018, 199: 609-618.

[2] XIE F Q, WU X H, ZHANG H Y, et al. Research on pulsed eddy current automatic detection technology for weld defects of pressure vessel cylinder[J]. Measurement, 2021, 176: 109081.

[3] BULLETTI A, GIANNELLI P, CALZOLAI M, et al. An integrated acousto/ultrasonic structural health monitoring system for composite pressure vessels[J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2016, 63(6): 864-873.

[4] KLUTE S M, METREY D R, GARG N, et al. In-situ structural health monitoring of composite-overwrapped pressure vessels[J]. Sampe Journal, 2016, 52(2): 7-17.

[5] HASAN M J, ISLAM M M M, KIM J M, et al. Multi-sensor fusion-based time-frequency imaging and transfer learning for spherical tank crack diagnosis under variable pressure conditions[J]. Measurement, 2021, 168(1): 108478.

[6] LIU C W, LI Y X, YAN Y K, et al. A new leak location method based on leakage acoustic waves for oil and gas pipelines[J]. Journal of Loss Prevention in the Process Industries, 2015, 35: 236-246.

[7] MOON C, BROWN W C, MELLEN S, et al. Ultrasound techniques for leak detection[C]//SAE Noise and Vibration Conference and Exhibition. [S.l.]: SAE, 2009:2159.

[8] MONES Z, ALQATAWNEH I, ZHEN D, et al.

- Fault diagnosis for planetary gearbox using on-rotor MEMS sensor and EMD analysis[C]//2019 25th International Conference on Automation and Computing (ICAC). Lancaster, UK: IEEE, 2019: 1-6.
- [9] 范春阳, 吴守鹏, 刘晓文, 等. 基于小波包变换与随机森林的滚动轴承故障特征分析方法[J]. 机械设计与制造, 2020(10): 59-63, 70.
FAN Chunyang, WU Shoupeng, LIU Xiaowen, et al. Fault feature analysis method of rolling bearing based on wavelet packet transform and random forest[J]. Machinery Design & Manufacture, 2020(10): 59-63, 70. (in Chinese)
- [10] LI H, FAN B, JIA R, et al. Research on multi-domain fault diagnosis of gearbox of wind turbine based on adaptive variational mode decomposition and extreme learning machine algorithms[J]. Energies, 2020, 13(6): 1375.
- [11] EL-ZAHAB S M, ASAAD A, ABDELKADER E M, et al. Development of a clustering-based model for enhancing acoustic leak detection[J]. Canadian Journal of Civil Engineering, 2018, 46(5): 278-286.
- [12] EL-ZAHAB S, MOHAMMED-ABDELKADER E, ZAYED T. An accelerometer-based leak detection system[J]. Mechanical Systems and Signal Processing, 2018, 108: 276-291.
- [13] SHUKLA H, PIRATLA K. Leakage detection in water pipelines using supervised classification of acceleration signals[J]. Automation in Construction, 2020, 117: 103256.
- [14] LI J, FAN X C, CHEN G R, et al. A DNN for small leakage detection of positive pressure gas pipelines in the semiconductor manufacturing[C]//2016 IEEE International Conference of Online Analysis and Computing Science (ICOACS). Chongqing, China: IEEE, 2016: 384-388.
- [15] WANG C, HAN F, ZHANG Y, et al. An SAE-based resampling SVM ensemble learning paradigm for pipeline leakage detection[J]. Neurocomputing, 2020, 403: 237-246.
- [16] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [17] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks[C]//2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH3 7541). Budapest, Hungary: IEEE, 2004: 985-990.
- [18] 陆慧娟, 安春霖, 马小平, 等. 基于输出不一致测度的极限学习机集成的基因表达数据分类[J]. 计算机学报, 2013, 36(2): 341-348.
- LU Huijuan, AN Chunlin, MA Xiaoping, et al. Disagreement measure based ensemble of extreme learning machine for gene expression data classification[J]. Chinese Journal of Computers, 2013, 36(2): 341-348. (in Chinese)
- [19] 刘伯相, 张远民, 江竹. 基于变分模态分解的管道泄漏信号降噪方法[J]. 振动、测试与诊断, 2023, 43(2): 397-403.
LIU Boxiang, ZHANG Yuanmin, JIANG Zhu. Pipeline leakage signal denoising method based on variational mode decomposition[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(2): 397-403. (in Chinese)
- [20] DAVIS S, MERMELSTEIN P. Comparison of parametric representations for monosyllabic Word recognition in continuously spoken sentences[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1980, 28(4): 357-366.
- [21] 嵇佳丽. 基于声信号特征分析的降雹检测方法研究[D]. 南京: 南京信息工程大学, 2022.
- [22] 车翔玖, 于英杰, 刘全乐. 增强Bagging集成学习及多目标检测算法[J]. 吉林大学学报(工学版), 2022, 52(12): 2916-2923.
CHE Xiangjiu, YU Yingjie, LIU Quanle. Enhance Bagging ensemble learning and multi object detection algorithm[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(12): 2916-2923. (in Chinese)
- [23] NICODEMUS K K. Letter to the editor: on the stability and ranking of predictors from random forest variable importance measures[J]. Briefings in Bioinformatics, 2011, 12(4): 369-373.
- [24] KIM M S, LEE S K. Detection of leak acoustic signal in buried gas pipe based on the time - frequency analysis [J]. Journal of Loss Prevention in the Process Industries, 2009, 22(6): 990-994.
- [25] GUYON I, ELISSEEFF A. An introduction of variable and feature selection[J]. The Journal of Machine Learning Research, 2003, 3: 1157-1182.



第一作者简介:何栋,男,2000年4月生,硕士生。主要研究方向为声纹识别。

通信作者简介:纪轩荣,男,1980年8月生,博士、教授、博士生导师。主要研究方向为超声无损检测。

E-mail: xr.ji@gdut.edu.cn