

中文引用格式:廖春燕,梁伟,刘双磊,等. 融合 Welch 功率谱和多尺度残差网络的油气管道缺陷诊断[J]. 中国安全科学学报, 2026, 36(2): 136-144.

英文引用格式:LIAO Chunyan, LIANG Wei, LIU Shuanglei, et al. Defect diagnosis method for oil and gas pipelines based on fusion of Welch power spectrum and multi-scale residual network[J]. China Safety Science Journal, 2026, 36(2): 136-144.

融合 Welch 功率谱和多尺度残差网络的 油气管道缺陷诊断*

廖春燕^{1, 2}, 梁伟^{**1, 2}教授, 刘双磊^{1, 2}, 黄天长^{1, 2}

(1 中国石油大学(北京)安全与海洋工程学院, 北京 102249;

2 应急管理部油气生产安全与应急技术重点实验室, 北京 102249)

中图分类号:X937

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.02.0599

【摘要】 为解决油气管道弯管检测信号受噪声污染导致缺陷分类准确率下降的问题,提出一种基于 Welch 功率谱特征增强和多头注意力改进型双分支多尺度-残差协同网络的油气弯管缺陷诊断模型。首先,利用基于汉明窗的 Welch 方法将采集到的时域信号转换为特征增强的功率谱,展示缺陷信号在不同频率处能量的分布情况;然后,并行堆叠的卷积层构成的多尺度网络分支负责提取信号功率谱的多维度特征,并利用多头注意力机制建立特征之间长期的关联,同时,残差网络分支捕捉信号功率谱的细节信息;最后,深度串联层融合双分支网络提取的特征,以实现缺陷分类。结果表明:在高噪声环境下,该模型的测试准确率为 91.6%,相比于基于凯塞窗和平顶窗的模型,分类准确率提高 1%~7.9%;相比于卷积神经网络(CNN)和长短时记忆网络(LSTM),准确率分别提高 36.9%和 10.3%。

【关键词】 Welch 功率谱; 多尺度残差网络; 油气管道; 弯管缺陷; 高噪声; 智能诊断

Defect diagnosis method for oil and gas pipelines based on fusion of Welch power spectrum and multi-scale residual network

LIAO Chunyan^{1, 2}, LIANG Wei^{1, 2}, LIU Shuanglei^{1, 2}, HUANG Tianchang^{1, 2}

(1 College of Safety and Ocean Engineering, China University of Petroleum (Beijing),

Beijing 102249, China; 2 Key Laboratory of Oil and Gas Safety and Emergency

Technology, Ministry of Emergency Management, Beijing 102249, China)

Abstract: To address the problem of reduced defect classification accuracy caused by noise contamination in the bend detection signals of oil and gas pipelines, this paper proposes an oil and gas elbow defect diagnosis model based on Welch power spectrum feature enhancement and multi-head attention improved dual-branch multi-scale-residual collaborative network. Firstly, the Welch method was used to convert the collected time domain signal into a feature-enhanced power spectrum, showing the energy distribution of the defect signals at different frequencies. Secondly, the multi-scale network branch

* 文章编号:1003-3033(2026)02-0136-09; 收稿日期:2025-09-06; 修稿日期:2025-12-04

** 通信作者:梁伟(1978—),男,陕西绥德人,博士,教授,博士生导师,主要从事油气生产安全监测与设备智能诊断、运维等方面的研究。
E-mail: tongxun_1978@126.com。

composed of parallel stacked convolutional layers was responsible for extracting the multi-dimensional features of the signal power spectrum, and the multi-head attention mechanism was used to establish long-term associations between features. Simultaneously, the residual network branch captured the detail information of the signal power spectrum. Finally, the deep concatenation layer fused the features extracted by the dual-branch network to achieve defect classification. The experiment results show that in a high-noise environment, the test accuracy of the proposed model is 91.6%. Compared with the models based on Kaiser windows and flat-top windows, the classification accuracy is improved by 1%~7.9%; compared with convolutional neural network (CNN) and long short-term memory network (LSTM), the accuracy is improved by 36.9% and 10.3% respectively.

Keywords: Welch power spectrum; multi-scale residual network; oil and gas pipeline; elbow defect; high noise; intelligent diagnosis

0 引 言

油气管道作为易燃易爆能源介质的运输生命线,其安全运行面临风险识别困难和事故应急处置复杂等多重挑战^[1-2]。从事故致因机理来看,管道结构缺陷往往是安全风险形成和事故演化的直接诱因。受服役时间延长、输送流体的冲刷侵蚀、第三方破坏等众多因素影响,油气管道中开裂、腐蚀、划痕等各种缺陷屡见不鲜,严重威胁着管道的安全可靠运行^[3-4],因此,检测与诊断管道缺陷对于保证其安全运行不可或缺。

目前,管道缺陷无损检测的方法众多,如漏磁检测、超声检测、磁涡流检测等。新兴的磁涡流检测能够在高提离度情况下有效检测覆盖防腐层的管道。然而,各类缺陷检测方法所获取的信号普遍受到环境噪声干扰^[5]。在磁涡流检测过程中,噪声主要源于被检管道材质不均匀等物理特性、周围磁场的扰动以及检测过程中的机械振动,而高噪声会掩盖或篡改时域信号中缺陷的有效特征,进一步影响管道缺陷诊断的准确性。针对噪声信号的分类问题,常用的解决方法是先对时域信号降噪,再提取降噪信号特征并利用传统机器学习算法如支持向量机等进行分类^[6],或者利用深度学习网络如一维卷积神经网络(Convolutional Neural Network, CNN)或长短时记忆网络(Long Short-Term Memory, LSTM)对降噪信号执行端到端的智能诊断。SHA Duolin 等^[7]提出一种基于导数极值的均值模态分解方法用于管道缺陷磁涡流检测信号的降噪;WANG Shuaishuai 等^[8]应用变分模态分解与离散小波变换相结合的方法,对包覆层下管道缺陷检测信号降噪,并将降噪后的信号用于后续 SENet-ResNet18 网络的分类处理;李友家等^[9]针对噪声淹没信号特征问题,提出

逐次变分模态方法以分解和重构轴承故障信号,并利用改进的 CNN 网络分类处理后的信号;KILADZE 等^[10]利用双向 LSTM 分类降噪预处理后的心电图信号。由此可见:当前基于降噪的诊断算法虽取得了一定成效,但还存在效率与精度不足的问题^[11-12]。

因此,笔者拟提出一种新的无需预先降噪的融合 Welch 功率谱特征增强和双分支多尺度残差网络的油气管道缺陷诊断方法。本方法集成 Welch 功率谱与多尺度卷积提取判别特征,利用多头注意力机制捕获特征关系,并引入残差模块,以期精准辨识与高效诊断管道缺陷。

1 弯管缺陷诊断相关理论

1.1 Welch 算法

功率谱是指基于傅里叶变换(Fast Fourier Transform, FFT)原理,研究检测信号在不同频率上功率谱密度变化曲线。功率谱峰值能反映检测信号有效成分的主频率,起到增强弱信号频域特征的作用^[13]。目前,计算信号功率谱的主要方法包括周期图法、Bartlett 法、Welch 法。经研究发现, Welch 法在弱信号的检测分析中具备更小偏差、方差和更好的频率分辨率^[14]。

Welch 法通过利用选择的窗函数在信号序列数据上滑动交叠截取、分段计算等步骤估计最终的信号功率谱,主要分为以下 5 步:

1) 分段信号。将信号 x 分成 M 段长度为 N 的截断信号,记为 $x_{i_1}[N]$;

$$M = \left\lfloor \frac{L - N}{N(1 - r)} + 1 \right\rfloor \tag{1}$$

式中: x 为原始信号; M 为截断信号数量; N 为截断

信号长度; i_1 为截断信号的索引, $1 \leq i_1 \leq M$; $\mathbf{x}_{i_1}[N]$ 表示第 i_1 个截断信号; L 为原始信号长度; r 为截断信号的重叠率。

2) 窗口化。应用窗口函数 $w[i_2]$ 对每个截断信号进行加窗处理,以汉明窗为例;

$$w[i_2] = 0.54 - 0.46\cos\left(\frac{2\pi i_2}{N}\right), 0 \leq i_2 \leq N-1 \quad (2)$$

$$\mathbf{X}_{i_1}[N] = \mathbf{x}_{i_1}[N] \times w[i_2] \quad (3)$$

式中: w 为窗函数; i_2 为窗函数样本点的索引, $0 \leq i_2 \leq N-1$; $\mathbf{X}_{i_1}[N]$ 为经窗口化的截断信号。

3) FFT。对 $\mathbf{X}_{i_1}[N]$ 进行 FFT, 得到每个截断信号的频谱。

$$\mathbf{X}'_{i_1} = \text{FFT}(\mathbf{X}_{i_1}[N]) \quad (4)$$

式中 $\mathbf{X}'_{i_1}$ 为截断信号的频谱。

4) 功率谱估计。执行下式以得到功率谱:

$$\mathbf{P}_{i_1} = \frac{1}{N} \times |\mathbf{X}'_{i_1}|^2 \quad (5)$$

式中 $\mathbf{P}_{i_1}$ 为截断信号的功率谱。

5) 平均并输出对数功率谱。计算所有功率谱的均值并执行对数运算:

$$\mathbf{P} = 10\lg\left(\frac{1}{M} \sum_{i_1}^M \mathbf{P}_{i_1}\right) \quad (6)$$

式中 $\mathbf{P}$ 为原始信号的功率谱。

窗口函数的选择原则是使得 Welch 功率谱的频率分辨率与频谱泄漏达到平衡。常用的窗口函数包括汉明窗、凯塞窗和平顶窗。为明确不同窗函数及其参数的选择对检测信号 Welch 功率谱估计以及诊断结果的影响,使用 3 种不同 β 值的凯塞窗^[15] ($\beta = 0, 5, 8.6$)、平顶窗分别与汉明窗作对比分析。图 1 为不同窗函数的波形。




图 1 不同窗口函数

Fig. 1 Different window functions

由图 1 可知:①汉明窗与 $\beta = 5$ 的凯塞窗变化趋势基本一致,两者的起始部分和结束部分稍有差异;②各窗口函数对分段信号的加窗处理不同,因此会对信号功率谱的频率分辨率和谱泄漏产生不同影响。

1.2 多头注意力

由于多尺度分支在处理 Welch 功率谱序列数据时对多维特征关系的建模有限,引入多头注意力机制^[16],以更有效地建立特征间全局关联,从而提升模型的表达能力。多头自注意力计算如下:

$$\mathbf{E}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{concat}(\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_{i_3})\mathbf{O} \quad (7)$$

式中: $\mathbf{E}$ 为多头注意力输出结果; $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询向量、键向量和值向量; concat 为串联操作; i_3 为自注意力的索引; $\mathbf{e}_{i_3}$ 为第 i_3 头自注意力的计算结果; $\mathbf{O} \in R^{h \times d''}$ 为线性变换矩阵; h 为总头数; d' 和 d'' 分别为查询键和模型的维度。

$$\mathbf{Q} = \mathbf{X}'\mathbf{W}^Q, \mathbf{K} = \mathbf{X}'\mathbf{W}^K, \mathbf{V} = \mathbf{X}'\mathbf{W}^V \quad (8)$$

式中: $\mathbf{X}' \in R^{c \times d'}$ 为多尺度特征输入序列; c 为特征序列长度; $\mathbf{W}^Q, \mathbf{W}^K, \mathbf{W}^V \in R^{d' \times d'}$ 分别为 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 的权重矩阵。

$$\mathbf{e}_{i_3} = \text{softmax}\left(\frac{\mathbf{Q}_{i_3}\mathbf{K}_{i_3}^T}{\sqrt{d'}}\right)\mathbf{V}_{i_3} \quad (9)$$

式中 softmax 为权重归一化函数。

1.3 多尺度模块

将 GoogLeNet 多尺度特征提取模块^[17]中的二维卷积更改为一维卷积以适应序列数据输入,并且减少各并行通道中卷积核的数量以轻量化模型,构建一种用于 Welch 功率谱特征提取的一维多尺度模块。在该模块中,各并行通道首层卷积核数量分别为 32、32、16 和 32,中间两通道第 2 层卷积核数量均为 64。卷积核用于提取 Welch 功率谱多层次特征,ReLU 层将提取的特征作非线性变换,池化层用于感知特征的全局表征。最后模块通过深度串联层拼接各并行通道编码的特征。

1.4 残差模块

为有效保留缺陷信号功率谱的细节特征并缓解模型训练过程中的梯度消失和爆炸问题,在智能诊断网络中引入残差模块分支。残差连接是其核心设计,能够简化网络训练的优化过程^[18]。

搭建的残差模块由 2 个带有批归一化层和 ReLU 层的卷积层构成,卷积层中卷积核大小和数量分别为 3 和 64。

2 弯管缺陷智能诊断模型

基于 Welch 功率谱、多头注意力机制、多尺度模块以及残差模块,提出一种新型油气弯管缺陷智能

诊断模型。整体流程如图 2 所示。所提模型基于磁涡流设备采集的弯管缺陷电压信号序列数据,以 Welch 功率谱转换增强缺陷信号特征,并利用图 3 的多尺度残差网络智能识别缺陷。




图 2 所提模型整体框架

Fig. 2 Overall framework of proposed model




图 3 诊断网络

Fig. 3 Diagnostic network

3 缺陷诊断模型验证与结果分析

3.1 检测设备介绍与数据集构建

由于油气弯管几何形状的复杂性,利用实验室

基于漏磁原理和脉冲涡流原理自主设计的小型磁涡流检测系统检测弯管缺陷。图 4 为检测系统的主要构成。




图 4 小型磁涡流检测系统

Fig. 4 Small magnetic eddy current testing system

检测设备以 200 Hz 的采样频率定点检测现场退役油气管道的腐蚀、划痕、焊缝开裂以及正常无缺陷表面。在实验室条件下采集腐蚀、划痕、焊缝开裂及正常信号样本数分别为 448, 369, 572 和 645, 每个信号样本采样点数为 512。同时考虑不同缺陷形状和尺寸对信号响应的影响,因此采集的每类缺陷均包含形状和尺寸上具有一定差异的样本。形状和深度均有一定差异的 3 种划痕信号如图 5 所示。通过统计发现,3 个信号主要是波动范围不同,且平均幅值也有所差异。




图5 不同的划痕及其对应的检测信号
Fig. 5 Different scratches and corresponding detection signals

图6为从实验室采集的4种油气管道缺陷信号。腐蚀信号混杂噪声最多;划痕信号与焊缝开裂信号高度相似,混杂噪声较少;正常信号波形类似正弦波且与其他3种缺陷信号存在明显差异。

为模拟现场噪声环境,在采集到的缺陷信号中分别加入信噪比(Signal-to-Noise Ratio, SNR)为10、5和0 dB的高斯白噪声,构建数据集2、3和4。表1为4个数据集代表信号的信噪比。

表1 各数据集不同缺陷信号的 SNR

缺陷类别	样本个数	各数据集代表信号的信噪比/dB			
		数据集1	数据集2	数据集3	数据集4
腐蚀	448	2.94	2.00	1.06	-0.42
划痕	369	13.78	5.63	0.29	-6.58
焊缝开裂	572	18.09	6.58	1.71	-1.04
正常	645	18.21	8.82	0.66	-4.11





图7 各数据集缺陷信号的 Welch 功率谱
Fig. 7 Welch power spectrum of defect signals in different datasets

3.2.2 基于凯塞窗和平顶窗的 Welch 功率谱转换

为明确窗函数及其参数选择对功率谱估计的影响,引入具有3个典型 β 值的凯塞窗和平顶窗作为对比方案,采用 Welch 方法估计数据集4中各缺陷




图6 数据集1
Fig. 6 Dataset 1

3.2 缺陷信号 Welch 功率谱转换

3.2.1 基于汉明窗的 Welch 功率谱转换

为平衡频率分辨率和频谱泄漏,选择汉明窗作为加窗函数,窗长设置为256,分段信号间的重叠率设置为50%。图7为4个数据集各类别缺陷信号的 Welch 功率谱。由图7a可以看出,各缺陷信号的有效频率范围。在不同噪声数据集中,各缺陷信号的 Welch 功率谱均较为平滑,频率的功率波动幅度很小,基本在10 dB 以内。由图7d可知:高噪声数据集4的 Welch 功率谱依然可以清晰分辨出各缺陷信号的有效频率范围。

信号功率谱。图8为基于凯塞窗和平顶窗下信号的 Welch 功率谱。图8a中,凯塞窗($\beta=0$)下信号 Welch 功率谱的旁瓣比汉明窗的高,尤其是信号主频率周围的旁瓣,反映了该窗下功率谱的频率分

分辨率低且旁瓣抑制能力差。图 8b 中,凯塞窗 ($\beta = 5$) 下信号的 Welch 功率谱与汉明窗下的功率谱极为相似,均能较好地平衡频率分辨率和频谱泄漏。图 8c 中,凯塞窗 ($\beta = 8.6$) 下信号 Welch 功率谱的主瓣相对稍宽,反映出该窗下的频率分辨

率较低。图 8d 中,平顶窗下的信号功率谱关注信号频率幅值准确性,忽略了其频率范围的精确性,这会加重不同信号主频率之间的重叠。综上,基于汉明窗转换的信号 Welch 功率谱在文中表现最优。




图 8 凯塞窗和平顶窗下各缺陷信号的 Welch 功率谱

Fig. 8 Welch power spectrum of different defect signals based on kaiser and flattop windows

3.3 评价指标

分类性能评价指标能够有效评估诊断网络在缺陷类型识别中的可靠性。评价指标主要包括整体的精确率 P 、召回率 R 、 F_1 以及准确度 A ,具体计算公式见文献[19]。

3.4 弯管缺陷诊断

文中模型基于表 1 中 4 种不同噪声程度的数据集进行训练。对于每种数据集,训练集、验证集以及测试集的划分比例分别为 70%、20% 和 10%。在训

练过程中,采用自适应矩估计优化算法,批量大小为 64,初始学习率为 10^{-3} ,学习率的策略为多项式下降。考虑到模型学习难度会随着噪声的增加而加大,数据集 1—数据集 4 的训练轮数分别设置为 40、60、80、80 轮。选用交叉熵损失函数参与模型参数的更新优化。另外,训练过程中验证频率设置为每 22 次训练迭代验证一次,并指定最佳验证模型作为输出模型,用于对测试集的智能诊断。图 9 为文中模型在各数据集上的训练和验证曲线。




图 9 不同数据集的训练及验证进度

Fig. 9 Training and validation progress graphs for different datasets

从图 9 可以看出,在 4 种不同噪声数据集上训练模型时,4 种评价曲线最终均收敛至稳定的良好状态。多尺度残差网络在信噪比越高的数据集上训练时,其训练振荡幅度越小且收敛速度越快。具体来说,在无添加噪声的数据集 1 上训练的模型,其训练准确率在第 9 轮时迅速达到 93%,并最终稳定在 97.5%。添加噪声 SNR 为 10dB 的数据集 2 上训练的模型,各曲线收敛速度减缓,且验证准确率曲线在前 40 轮存在小幅振荡。模型最终训练和验证准确率分别为 99.3%和 99%,说明模型并未因小噪声的干扰而降低识别准确率。添加噪声 SNR 为 5dB 的数据集 3 训练的模型,其训练准确率曲线缓慢攀升,最终准确率为 99.7%。验证准确率曲线前期同样出现一定程度的波动,第 34 轮后逐渐趋于稳定,最终验证准确率为 98.5%。噪声最大的数据集 4 训练的模型,其训练和验证准确率曲线均出现小幅振荡,后期趋于收敛,最终的训练和验证准确率分别为 99.5%和 92.2%。现实中,SNR 为 0dB 的噪声已完全达到了现场的高噪声状态,此时的准确率满足需求。

进一步地,利用上述经训练的各模型分类诊断各数据集下的测试数据,准确率分别为 94.6%、98.0%、95.6%和 91.6%。结果表明:对于不同噪声

数据集,多尺度残差网络的分类准确率依然在 91.6%以上,说明模型具有良好的鲁棒性和辨别能力。

3.5 对比分析

3.5.1 基于不同窗函数的诊断结果对比

为明确不同窗函数及其参数的选择对诊断结果的影响,将所提模型中的窗函数分别修改为 3 个凯塞窗($\beta = 0, 5, 8.6$)和平顶窗,并将修改后模型基于高噪声数据集 4 进行训练、验证和测试。除窗口函数外,训练时其他参数设置与 3.4 节保持一致。图 10 为不同窗函数及同一凯塞窗下不同参数选择的训练和验证准确率进度。由图 10 可知:基于汉明窗的模型收敛速度最快,稳定性最好。 $\beta = 0$ 的凯塞窗模型准确率曲线攀升较慢,且验证中后期振荡幅度较大。 $\beta = 5$ 的凯塞窗模型在经历前期迭代的振荡后,最后的诊断准确率逼近汉明窗模型。 $\beta = 8.6$ 的凯塞窗模型初期收敛速度快,但最终的收敛状态欠佳。而平顶窗模型的诊断效果一般,收敛速度慢且较为振荡。经训练后,利用上述各窗口模型诊断数据集 4 的测试集,各项评价指标见表 2。4 种评价指标的统计结果进一步印证了汉明窗模型最优、凯塞窗模型次之,而平顶窗模型较差。




图 10 不同窗函数下模型训练及验证准确率曲线

Fig. 10 Training and validation accuracy curves under different window functions

表 2 不同窗函数下诊断模型在测试集上的评价结果

Table 2 Evaluation results of diagnosis models based on different windows on test set %				
窗函数	评价指标			
	精确率 P	召回率 R	F_1	准确率 A
汉明窗	90.9	91.0	90.9	91.6
凯塞窗 $\beta = 0$	89.3	89.0	89.2	90.2
凯塞窗 $\beta = 5$	90.2	89.0	89.4	90.6
凯塞窗 $\beta = 8.6$	83.8	83.3	83.5	85.2
平顶窗	82.1	81.8	81.7	83.7

3.5.2 不同网络的对比分析

为验证文中模型在高噪声数据分类上的优越性,选用经典的 CNN 和 LSTM 模型基于数据集 4 进行对比试验。模型的训练环境与各项参数与 3.4 节保持一致。训练及验证如图 11 所示,经过 20 轮训练后,CNN 网络的训练和验证准确度曲线分别稳定在 50%和 60%左右,损失分别稳定在 0.82 和 0.85。后续的训练未能改善其分类性能,表明 CNN 受到高噪声的干扰未能学习到有效的缺陷特

征。对于 LSTM,在前 23 轮训练过程中,训练和验证曲线存在大幅度振荡。23 轮后,训练和验证曲线缓慢收敛。最后一轮的训练和验证准确度分别为 80.1% 和 79.7%,训练和验证损失分别为 0.43 和 0.44,说明 LSTM 对缺陷时域数据的分类学习

能力有限。

利用经训练的本文模型、CNN 以及 LSTM,分类数据集 4 中的测试集,评价结果见表 3。文中模型的各项评价指标最优,在分类准确率上高出 CNN 模型 36.9%,高出 LSTM 模型 10.3%。




图 11 CNN 及 LSTM 训练及验证进度

Fig. 11 Training and validation progress charts of CNN and LSTM

表 3 不同模型在测试集上的评价结果

Table 3 Evaluation results of different models on test set

模型	评价指标			
	精确率 P	召回率 R	F_1	准确率 A
本文模型	90.9	91.0	90.9	91.6
CNN	45.8	51.8	47.9	54.7
LSTM	78.8	76.5	74.9	81.3

准确率为 94.6%,98.0%,95.6% 和 91.6%,能够准确区分不同噪声信号的缺陷类型。相比于基于凯塞窗 ($\beta = 0,5,8.6$) 和平顶窗的模型,准确率提高 1%~7.9%;相比于基线模型 CNN 和 LSTM,准确度分别提升 36.9% 和 10.3%。基于汉明窗的 Welch 功率谱和多尺度残差网络的模型在弯管缺陷智能诊断中,具备一定的有效性和可用性,可为管理者制定决策提供参考。

4 结 论

1) 文中提出的弯管缺陷智能诊断模型,高分类

2) 文中研究的重点是定性分类弯管缺陷,尚未量化预测缺陷尺寸。未来将重点拓展该模型的回归预测功能,以增强其工程实用价值。

参考文献

[1] 姜垣良,任庆滢,任远,等. 基于改进 YOLO 模型的中缅油气管道遥感图像高后果区识别方法[J]. 中国安全科学学报,2025,35(1):103-111.

JIANG Yuanliang, REN Qingying, REN Yuan, et al. High-consequence area identification of remote sensing images of China-Myanmar oil and gas pipeline based on improved YOLO model[J]. China Safety Science Journal, 2025, 35(1): 103-111.

[2] 宫运华,张喆. 油气管道事故应急失效原因及社会网络分析[J]. 中国安全科学学报,2025,35(1):209-215.

GONG Yunhua, ZHANG Zhe. Failure causes of emergency response in oil and gas pipeline accidents and social network analysis[J]. China Safety Science Journal, 2025, 35(1): 209-215.

[3] HUANG Songling, PENG Lisha, SUN Hongyu, et al. Deep learning for magnetic flux leakage detection and evaluation of oil & gas pipelines: a review[J]. Energies, 2023, 16(3): DOI:10.3390/en16031372.

[4] 王轲,黄成橙,王鹏. 深度学习在油气管道漏磁检测领域的应用[J]. 无损检测,2024,46(12):93-99.

WANG Ke, HUANG Chengcheng, WANG Peng. Application of deep learning in magnetic leakage detection of oil and gas pipelines[J]. Nondestructive Testing, 2024,46(12):93-99.

[5] WU Linyu, LIANG Wei, SHA Duolin. A novel adaptive noise reduction method for field natural gas pipeline defect

- detection signals[J]. International Journal of Pressure Vessels and Piping, 2022, 199: DOI: 10.1016/j.ijpvp.2022.104761.
- [6] 武琳玉,梁伟,沙夺林. 油气站场典型设备的焊缝缺陷检测与识别方法[J]. 中国安全科学学报, 2020, 30(11): 108–113.
- WU Linyu, LIANG Wei, SHA Duolin. Weld defect detection and identification method of typical equipment in oil-gas station[J]. China Safety Science Journal, 2020, 30(11): 108–113.
- [7] SHA Duolin, LIANG Wei, WU Linyu. A novel noise reduction method for natural gas pipeline defect detection signals[J]. Journal of Natural Gas Science and Engineering, 2021, 96: DOI:10.1016/j.jngse.2021.104335.
- [8] WANG Shuaishuai, LIANG Wei, SHI Fang. Identification of coating layer pipeline defects based on the GA-SENet-ResNet18 model[J]. International Journal of Pressure Vessels and Piping, 2024, 212: DOI: 10.1016/j.ijpvp.2024.105327.
- [9] 李友家,张忠伟,焦宗豪,等. 强噪声干扰下基于 SVM-FFCNN 的深沟球轴承故障分类模型[J]. 机电工程, 2025, 42(4): 686–696.
- LI Youjia, ZHANG Zhongwei, JIAO Zonghao, et al. Fault classification model of deep groove ball bearing under strong noise interference based on SVM-FFCNN[J]. Journal of Mechanical & Electrical Engineering, 2025, 42(4): 686–696.
- [10] KILADZE M. Application of bidirectional LSTM neural networks and noise pre-cleaning for feature extraction on an electrocardiogram[C]. International Conference on Actual Problems of Applied Mathematics and Computer Science (APAMC), 2022: 421–429.
- [11] KAY K. The risk of bias in denoising methods: examples from neuroimaging[J]. PloS One, 2022, 17(7): DOI: 10.1371/journal.pone.0270895.
- [12] PICHIKA S V V S N, KASAM V, RAJASEKHARAN S G, et al. Automatic signal denoising and multi-component fault classification based on deep learning using integrated condition monitoring in a wind turbine gearbox[J]. Journal of Vibration Engineering & Technologies, 2024, 12(7): DOI:10.1007/s42417-024-01380-6.
- [13] 邢晓晴,朱根民. Welch 功率谱估计中窗函数的选择与算法分析[J]. 计算机时代, 2018(2): 1–4.
- XING Xiaoping, ZHU Genmin. Window function selection and algorithm analysis in Welch power spectrum estimation[J]. Computer Era, 2018(2): 1–4.
- [14] 杨婧,程乃平,倪淑燕. Welch 算法在弱信号检测中的性能分析[J]. 计算机仿真, 2020, 37(5): 235–240.
- YANG Jing, CHENG Naiping, NI Shuyan. Performance analysis of Welch algorithm in weak signal detection[J]. Computer Simulation, 2020, 37(5): 235–240.
- [15] OPPENHEIM A V, SCHAFER R W, BUCK J R. Discrete-time signal processing[M]. Upper Saddle River: Prentice Hall, 1999: 475–487.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]. 31st Annual Conference on Neural Information Processing Systems (NIPS), 2017: 5998–6008.
- [17] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[J]. CoRR, 2014: DOI:10.1109/cvpr.2015.7298594.
- [18] 李强,马超,黄民. 基于注意力的多尺度残差卷积网络轴承故障诊断[J]. 电子测量技术, 2025, 48(9): 19–26.
- LI Qiang, MA Chao, HUANG Min. Attention-based multi-scale residual convolutional network for bearing fault diagnosis[J]. Electronic Measurement Technology, 2025, 48(9): 19–26.
- [19] LIAO Chunyan, LIANG Wei, YAO Junming, et al. Intelligent defect diagnosis for oil and gas pipeline based on lightweight CBAM-Inception-Resnet[J]. Chemical Engineering Research and Design, 2025, 218: 548–571.

作者简介：廖春燕（1994—），女，广东肇庆人，博士研究生，主要研究方向为油气生产安全监测与设备智能诊断、运维等。E-mail: 2023310522@student.cup.edu.cn。

