

基于双分支网络和领域对抗的埋地管道 状态识别研究*

林俊泽 蔡志钦 陈彬强

(厦门大学航空航天学院 厦门 361005)

摘要:针对活动断裂带、采空区跨工况埋地管道不同的服役环境,在不同工况下的不同故障模式下的应变有着差异性且埋地管道采空区数据库建立较为困难的现状,直接影响了埋地管道在线监测的预警精度难题。为建立埋地管道健康状态与监测应变特征的对应关系,提出一种基于双分支网络和领域对抗的跨工况埋地管道状态识别方法。该方法首先使用双分支网络训练出埋地管道在活动断裂带工况下的识别模型;模型准确率为94.95%,提高活动断裂带预警精度,进一步根据活动断裂带、采空区数据特征联系,接着使用领域对抗的方法训练出采空区埋地管道健康状态与应变对应关系网络模型;可以实现小样本下采空区精准预测。最后通过实验表明该方法在线监测的预警精度为96.61%,证实该方法有效性。

关键词:管道健康状态;应变;双分支网络;领域对抗

中图分类号: TP302.2; TN98 **文献标识码:** A **国家标准学科分类代码:** 440.55

State recognition of buried pipelines under cross-working conditions based on two-branch network and domain antagonism

Lin Junze Cai Zhiqin Chen Binqiang

(School of Aerospace Engineering, Xiamen University, Xiamen 361005, China)

Abstract: For active fracture zones, air-mining zones across the conditions of buried pipelines in different service environments, under different conditions of different failure modes under the strain has a difference and buried pipelines in the air-mining zones of the database is more difficult to establish the status quo, directly affecting the buried pipeline on-line monitoring of the early warning accuracy of the problems. In order to establish the correspondence between the health state of buried pipelines and the monitoring strain characteristics, a method for recognizing the state of buried pipelines across working conditions based on two-branch network and domain confrontation is proposed. The method firstly uses a two-branch network to train a recognition model of buried pipelines under active fracture zone conditions; the accuracy of the model is 94.95%, which improves the early warning accuracy of active fracture zones, and then trains a network model of the correspondence relationship between the health state of buried pipelines and the strains in the mining area using domain confrontation based on the linkage of the data characteristics of active fracture zones and the mining area; this method can realize the accurate prediction of the mining area with small samples. Finally, the experiment shows that the warning accuracy of online monitoring is 96.61%, which confirms the effectiveness of this method.

Keywords: pipeline health status; strain; two-branch network; domain-adversarial

0 引言

我国幅员辽阔,但是地震中高风险区分布广泛,属于

地震多发国家。埋地油气管道作为典型的线性工程,往往需要穿越此类区域,地震产生的地表位错可能造成管道屈曲变形和拉断^[1-2]。土体不均匀沉降对管道的影响从开始

收稿日期:2024-09-12

* 基金项目:国家自然科学基金(52475070)项目资助

到感知是一个循环渐进的过程,如果在这个演变过程中对埋地管道进行状态监测,将会降低管道断裂、泄漏的可能性,因此,基于大应变的油气管道状态识别技术研究对于穿越高风险区域管道安全具有重要意义。

针对断层作用下埋地管道的状态分析方法主要有理论解析法和数据驱动法。理论解析法主要通过应变解析方法。Karamitros等^[3]考虑断层附近管道截面应力非线性分布,提出了一种管道塑性区间等效刚度的计算方法。Trifonov等^[4]在考虑了管道轴向力、内压与温度对挠曲线方程的影响,进一步优化了计算模型^[5]。学者们不断提出经验回归公式^[6]、半经验预测公式^[7],准确预测埋地管道应变响应,为埋地管道设计提供参考。但解析法存在两大不可消除的限制:1)解析法并不适用于管道受压的计算;2)模型基于梁理论,无法模拟管道的局部屈曲等行为,难以对管道状态进行快速的识别。

基于数据驱动的方法不必建立动力学模型,可以通过历史数据建立和优化模型,从而在变工况环境下取得良好的辨识结果^[8]。罗宏林等^[9]提出一种针对有限数量变工况下的轴承故障诊断方法,以实现变工况下轴承故障的准确诊断。周长巍等^[10]提出域适应和流形正则化的轴承故障诊断建模方法,利用流形正则化方法稳定数据的局部几何结构。Liu等^[11]提出一种基于对抗判别域自适应迁移学习网络的燃气轮机故障诊断方法,提高故障诊断精度。当前,国内外在变工况环境下的管道检测手段还有待挖掘。具体表现在实际运行过程中,由于管道材料、土体压力和变工况导致实际环境复杂多变,测试数据与训练数据的特征空间分布不一致,模型的性能通常受到限制,而迁移学习放宽了测试数据与训练数据需独立同分布的约束,在实际工作场景中,迁移学习能够挖掘两个域之间相关的领域不变特征^[12]。更为重要的是在针对采空区的应变数据库建立较为困难、样本较少的情况下,迁移学习能够将源域学习到的特征信息融合到目标域去;提高埋地管道的预警精度。

本文提出双分支网络用于跨断层管道在活动断裂带下的状态识别,同时将此模型作为特征提取器提取活动断裂带的特征;针对将活动断裂带迁移到采空区存在源域与目标域难以完全对齐的问题,本文提出一种领域对抗的跨工况知识迁移方法,将两工况的特征进行信息融合提高采空区的预警精度。最后通过实验验证该方法的可行性。

1 双分支网络和领域对抗的跨工况埋地管道状态识别方法

本文提出一种基于双分支网络和领域对抗的迁移学习模型,网络结构如图1所示,该网络包含特征提取、域对抗和分类器3个部分。所提方法采用卷积神经网络-长短期记忆(CNN-LSTM)双分支网络作为特征提取器从应变时频信号中直接提取高维特征,对源域数据采用有监督学

习方法训练出分类器,让分类器准确识别源域的管道状态。在域适配阶段,基于领域对抗的思想将特征提取器与判别器进行对抗学习增强;学习源域和目标域公共特征能力,从而减少领域差异。

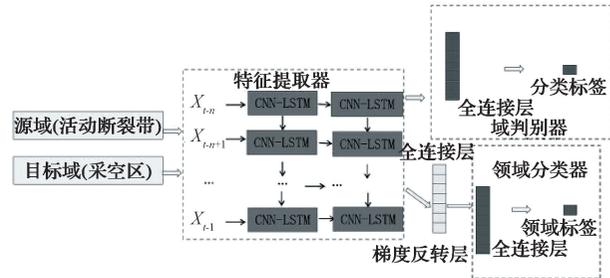


图1 跨工况埋地管道状态识别模型

Fig.1 State identification model of buried pipeline under cross-working conditions

领域分类器和特征提取器之间存在对抗机制。特征提取器提取不变特征,导致领域分类器很难区分特征的来源。而梯度反转层位于特征提取器和领域分类器之间。其目的是减少源域和目标域之间的差异,从而使领域分类器更难区分域标签。式(1)和(2)分别表示梯度反转层的正向传播和反向传播公式,在正向传播期间,梯度反转层可以切换身份。在反向传播中,它从下一层获得梯度。

$$G_{\lambda}(x) = x \quad (1)$$

$$\frac{dG_{\lambda}}{dx} = -\alpha \mathbf{I} \quad (2)$$

式中: \$\mathbf{I}\$ 是单位矩阵; \$\alpha\$ 是超参数为正数,用来衡量损失; \$\lambda\$ 是常数。然后使用梯度下降法更新模型参数优化 \$G_{\lambda}\$,优化方程如下式:

$$\begin{aligned} \phi(\theta_f, \theta_y, \theta_d) = & \frac{1}{N_s} \sum_{i=1}^{N_s} \phi_y(S_y(S_f(x_i; \theta_f); \theta_y), y_i) + \\ & \frac{1}{N_T} \sum_{i=1}^{N_T} \phi_y(S_y(S_f(x_i; \theta_f); \theta_y), y_i) + \\ & \frac{1}{N_s} \sum_{i=1}^{N_s} \phi_d(S_d(R(S_f(x_i; \theta_f); \theta_d), d_i)) + \\ & \frac{1}{N_T} \sum_{i=1}^{N_T} \phi_d(S_d(R(S_f(x_i; \theta_f); \theta_d), \theta_d)) \end{aligned} \quad (3)$$

式中: \$\theta_f, \theta_y\$ 和 \$\theta_d\$ 分别是特征提取器 \$S_f\$、域判别器 \$S_y\$ 和分类器 \$S_d\$ 的网络连接权重; \$N_s, N_T\$ 为源域和目标域的训练数量。

1.1 双分支网络

CNN是一种具有深度学习算法的前馈神经网络,在深度学习领域最具有代表性,具有分类能力强、泛化能力强等优点,逐步应用于标签分类等方面。LSTM网络是典型深度学习方法,由于其对数据分析的高精度预测,在标签分类领域被大量应用。LSTM中的存储单元和门机制可以解决梯度消失或梯度爆炸问题。

双分支网络具有复杂性和灵活性,能够更好适应不同分布的数据类型,从而减少模型的过拟合风险,提高模型的表达能力和泛化能力^[13]。本文提出的双分支网络模型由 CNN-LSTM 组成,整个网络结构如图 2 所示。模型是由 CNN 并联 LSTM 组成的双分支网络,模型输入时频应变信号,经过卷积、最大池化操作之后得到特征向量;将特征向量输入到一个全连接层中,然后通过 ReLU 激活函数进行非线性变换得到局部信息。输入经过 LSTM 层得到特征向量;将特征向量输入到一个全连接层中,然后通过 ReLU 激活函数进行非线性变换得到全局信息。通过将局部信息和全局信息拼接起来,可以得到更加丰富和全面的特征表示。最后将这些特征输入到全连接层进行分类,全连接层将输入特征映射到输出空间,从而实现对埋地管道状态的监测。

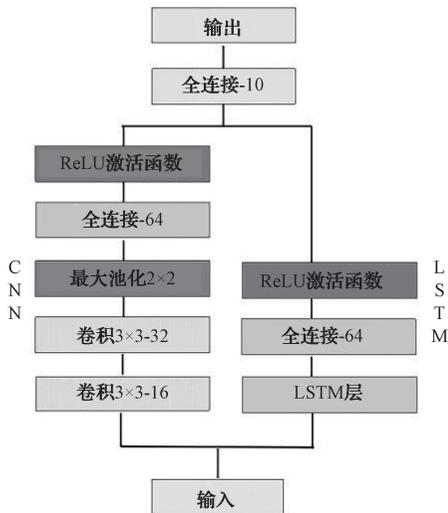


图 2 双分支网络结构

Fig. 2 Two-branch network structure

1.2 领域对抗

领域对抗神经网络 (domain adversarial neural net-

work, DANN)^[14] 是基于对抗的深度迁移学习策略。DANN 结合了特征提取和领域自适应。该模型由特征提取器 S_f 、回归预测器 S_y 和领域分类器 S_d 组成。双分支网络 CNN-LSTM 是特征提取器,从来自源域和目标域的训练数据中提取应变特征。域判别器和分类器都是完全连接层,域判别器找到应变和土体位移之间的映射关系。

DANN 领域分类损失值根据 DANN 模型的训练优化损失值估计,领域分类损失为:

$$L_y\{G_y[G_f(x_i)], y_i\} = \log \frac{1}{G_y[G_f(x_i)]_{y_i}} \quad (4)$$

式中: y_i 为埋地管道断裂状态; $G_f(x_i)$ 为信号经过特征提取器的特征; $G_y[G_f(x_i)]$ 为特征 $G_f(x_i)$ 经过 Softmax 函数的输出结果。域判别的损失度量领域自适应的效果,其损失函数为:

$$L_d\{G_d[G_f(x_i)], d_i\} = d_i \log \frac{1}{G_d[G_f(x_i)]} + (1 - d_i) \log \frac{1}{G_d[G_f(x_i)]} \quad (5)$$

式中: d_i 为领域标签; $G_f(x_i)$ 为信号经过特征提取器的特征; $G_d[G_f(x_i)]$ 为特征 $G_f(x_i)$ 经过 Sigmoid 激活函数后的输出。最后整个领域对抗网络的损失函数为:

$$E(\theta_f, \theta_y, \theta_d) = \frac{1}{n_s} \sum_{x_i \in D_s} L_y(G_y(G_f(x_i)), y_i) - \frac{1}{n_s + n_t} \sum_{x_i \in D_s \cup D_t} L_d(G_d(G_f(x_i)), d_i) \quad (6)$$

式中: L_y 和 L_d 分别是分类器 G_y 和域判别器 G_d 的损失; θ_f 、 θ_d 和 θ_y 分别是 G_f 、 G_d 和 G_y 的网络参数。

2 跨断层埋地管道试验

2.1 试验系统介绍

本文以走滑断层下埋地管道为研究对象开展模型试验设计,综合考虑结构的稳定性、便捷性再结合满足实验室的条件基础上设计了跨走滑断层埋地管道试验台,试验台整体结构如图 3 所示。

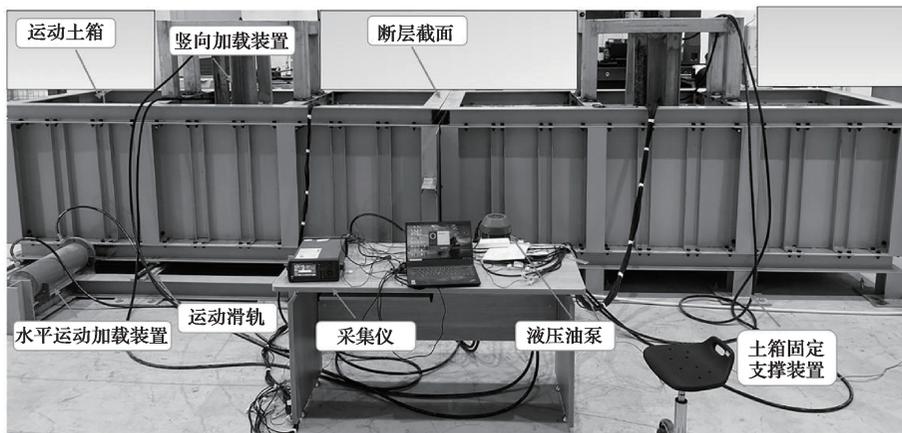


图 3 跨走滑断层埋地管道试验台

Fig. 3 Buried pipeline test bed across strike-slip fault

本文选取管径 89 mm、壁厚 4 mm 的 X80 管道和粉质黏土作为模型试验材料,设定管道埋深为 0.15 m,施加土体附加压力为 0.033 MPa。试验选用电阻值为 $120 \pm 1 \Omega$,灵敏度为 $2.0 \pm 1\%$,量程为 20 000 $\mu\epsilon$,敏感栅尺寸为 10 mm \times 5 mm,基底尺寸为 15 mm \times 9 mm 的 120-10AA 金属箔式电阻应变计对管道应变进行测试。DAQ970A 数据采集系统负责应变信号采用。

2.2 试验过程与数据集获取

首先,通过竖向加载装置对加压板加压到 0.033 MPa 时,将液压系统调整为保压状态。然后,通过水平加载装置对运动土箱进行位移加载,让运动土箱与固定土箱产生滑动,每次加载长度为 0.1 m,直至加载到 0.4 m。重复大量试验得到 1 800 组管道应变数据集。接着对所有数据进行时频域特征提取,共提取信号的 22 种时频域特征。

2.3 试验结果分析

本文针对模型试验工况建立跨断层埋地管道有限元模型并计算,将仿真结果与试验结果进行对比,结果如图 4 所示。

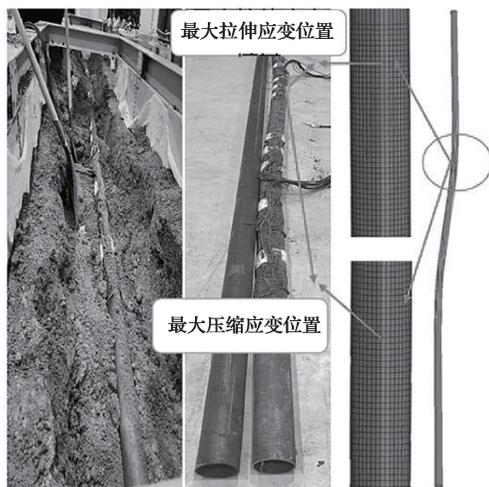


图 4 试验台模型与有限元模型对比

Fig. 4 Comparison between test bench model and finite element model

由图 4 可以看出,试验管道发生了明显的变形,变形形状呈反对称分布,管道最大应变位置出现在距离断面一定距离处;结合有限元模型对比,不难看出二者变形情况高度吻合,进一步很好地反映出该试验的准确性、合理性。

3 实验及结果分析

3.1 数据及预处理

本文通过跨走滑断层埋地管道试验台得到活动断裂带与采空区应变数据集,其中活动断裂带 1 200 组;采空区 600 组,共计 1 800 组应变数据集。在特征提取器中,将活动断裂带生成的 1 200 组应变时频特征按照 4 : 1 随机

划分为训练集和测试集,其中训练集共有 960 组,测试集共有 240 组。

3.2 特征提取器的性能分析

为了验证特征提取器具有优越性能,表 1 是本文经过多次训练得到的最优参数。实验采用准确率作为评估模型性能指标。

表 1 特征提取器模型的超参数

Table 1 Hyperparameters of the feature extractor model

超参数	所选参数
学习率	0.001
批量大小	64
迭代次数	200
优化器	Adam
损失函数	交叉熵损失
正则化参数	0.5

采用单、双分支网络在相同的参数下进行对比。本文所提 CNN-LSTM 和其他不同分支 CNN、LSTM、CNN-CNN 和 LSTM-LSTM 的测试准确率对比如图 5 所示,可以明显看出,本文所提 CNN-LSTM 模型前 50 轮中准确率有略微波动,50 轮之后收敛;LSTM-LSTM 在第 10 轮之后最快收敛,然后便轻微波动;CNN-CNN 和 CNN 在第 50 轮之后开始收敛,速度最缓慢;LSTM 模型虽然快速收敛但是后面相对波动较大。综上所述,本文所提 CNN-LSTM 模型收敛效果好,波动相对较小为最优模型。

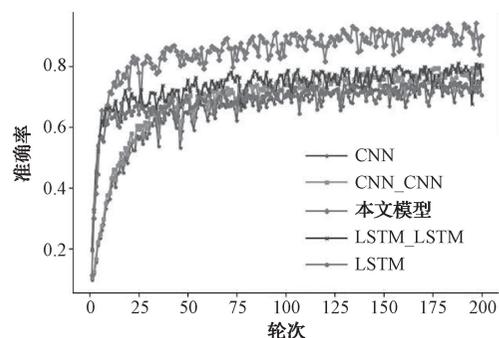


图 5 单双分支网络的测试准确率变化曲线

Fig. 5 Test accuracy curve of single-double branch network

训练完单、双分支网络的测试准确率如图 6 所示。从柱状图可以看出本文所提 CNN-LSTM 模型的测试准确率为 94.95%;CNN、LSTM、CNN-CNN 和 LSTM-LSTM 的测试准确率分别为 68.75%、70.48%、83.25% 和 81.73%。可以明显看出 CNN-LSTM 模型的准确率最高,证明其性能最佳,因此特征提取器选用 CNN-LSTM 模型。

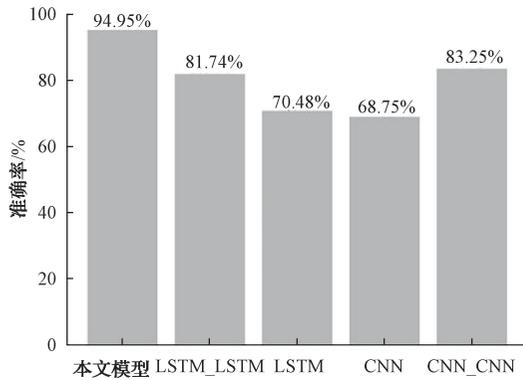


图6 单双分支网络的测试准确率

Fig.6 Test accuracy of single-dual branch network

3.3 不同迁移方法对比

为了验证基于双分支网络和领域对抗的跨工况埋地管道状态识别方法的优越性,本文采用俩类经典的迁移学习方法作对比。

1)基于映射的深度迁移学习方法,通过神经网络将源域和目标域的实例映射到特征空间,在特征空间中,通过距离度量使域散度最小化。如多核最大均值误差(MK-MMD)和联合最大均值差异(JMMD)度量距离的域适应方法。

2)基于对抗性的深度迁移学习,利用域鉴别器减少深度特征提取器产生的源域和目标域之间特征分布差异,如本文所提方法和深层域混淆(DDC)。

采用MK-MMD、JMMD和DDC3种迁移学习方法与本文方法对比。4种方法在迁移任务从活动断裂带迁移到采空区的测试准确率如图7所示。

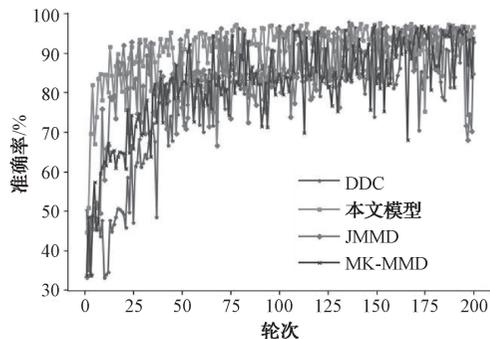


图7 不同迁移方法的测试集准确率曲线

Fig.7 Test set accuracy curve of different migration methods

由图7可知,本文所提DANN的方法在50轮之后进行收敛,整体准确率基本都在90%以上波动较平;MK-MMD和JMMD波动十分剧烈,总体来说分类效果变化较大;DDC在大概第75轮后才开始收敛但是分类整体准确率偏低。表2是不同迁移方法的测试集准确率。可以看

出本文方法的测试准确率为96.61%,MK-MMD、JMMD和DDC的测试准确率分别为93.83%、92.83%和84.83%,虽然MK-MMD和JMMD也具有良好的测试准确率,但是考虑到这两种方法波动性太大且测试准确率也没有本文所提方法高,再次验证本文方法的优越性。同时迁移之后的效果比未迁移之后的埋地管道状态分类效果更好,说明在结合活动断裂带的特征信息后,模型更具有准确性,进一步验证本文所提迁移方法的有效性和可靠性。

表2 不同迁移方法的测试集准确率

Table 2 Test set accuracy of different migration methods

迁移方法	准确率/%
本文模型	96.61
DCC	84.83
JMMD	92.83
MK-MMD	93.83

为了检验迁移学习方法对迁移效果的影响,利用T-SNE^[15]特征降维方法对迁移任务的高频特征提取结果可视化。不同迁移方法的特征迁移结果如图8所示。图8中DANN是本文方法的特征可视化结果,可以明显看出,目标域的分类效果最好,各个分类点误分到其他中心的特征结果最少,证明模型效果最好;接着依次是MK-MMD、JMMD和DDC可视化效果依次递减,这与上文所提测试集准确率效果一致,同时也验证本文所提模型具有更优的迁移能力。

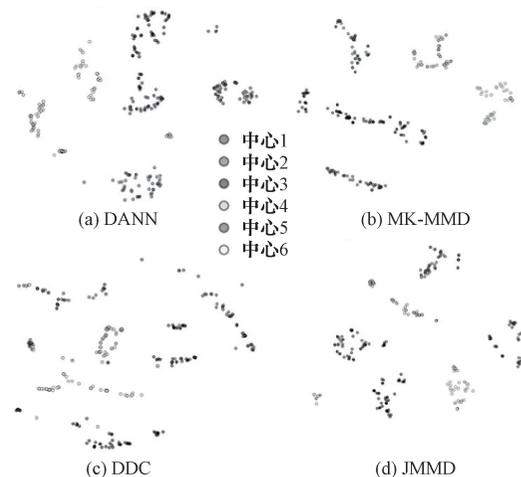


图8 不同迁移方法的特征迁移结果

Fig.8 Feature migration results of different migration methods

4 结论

为建立埋地管道健康状态与监测应变特征的对应关系,本文提出一种基于双分支网络和领域对抗的埋地管道

状态识别方法,首先在活动断裂带训练出特征提取器;同时对比其他4种单双分支网络的准确率来确定最佳特征提取网络,然后使用领域对抗的方法迁移到采空区;同时和其他3种经典迁移学习方法作对比,并通过特征可视化来进一步验证本文所提方法优越性。实验结果表明,本文所提双分支网络与领域对抗的跨工况埋地管道状态识别方法准确率达到96.61%。在采空区风险区下应变数据库建立困难、人力和物力耗费较大的情况下,本文对于采空区埋地管道的状态监测提供了新思路,具有一定的工程意义。

参考文献

- [1] 黄子明,贺继林.面向水下管网的视觉检测系统研究[J].电子测量与仪器学报,2021,35(6):79-87.
HUANG Z M, HE J L. Research on visual inspection system for underwater pipeline network[J]. Journal of Electronic Measurement and Instrumentation, 2021,35(6):79-87.
- [2] 居海华,张乐,夏忠,等.基于铯光泵磁力仪的地震地磁矢量测量系统[J].仪器仪表学报,2023,44(9):111-120.
JU H H, ZHANG L, XIA ZH, et al. Seismic geomagnetic vector measurement system based on optically pumped cesium magnetometer[J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 111-120.
- [3] KARAMITROS D K, BOUCKOVALAS G D, KOURETZIS G P. Stress analysis of buried steel pipelines at strike-slip fault crossings [J]. Soil Dynamic & Earthquake Engineering, 2007, 27(3): 200-211.
- [4] TRIFONOVOV O V, CHERNIY V P. A semi-analytical approach to a nonlinear stress-strain analysis of buried steel pipelines crossing active faults[J]. Soil Dynamics & Earthquake Engineering, 2010, 30(11): 1298-1308.
- [5] TRIFONOVOV O V, CHERNIY V P. Elastoplastic stress-strain analysis of buried steel pipelines subjected to fault displacements with account for service loads [J]. Soil Dynamics & Earthquake Engineering, 2012, 33(1): 54-62.
- [6] CHENG X, PANG M, XU L, et al. Seismic response analysis of buried pipelines crossing oblique slip faults based on a strain design[J]. Natural Gas Industry, 2016, 36: 110-117.
- [7] LIU X B, ZHANG H, HAN Y S, et al. A semi-empirical model for peak strain prediction of buried X80 steel pipelines under compression and bending at strike [J]. Journal of Natural Gas Science & Engineering, 2016, 32: 465-475.
- [8] 代浩,金铭,陈星,等.数据驱动的应用自适应技术综述[J].计算机研究与发展,2022,59(11):2549-2568.
DAI H, JIN M, CHEN X, et al. Survey of data-driven application self-adaptive technology [J]. Journal of Computer Research and Development, 2022, 59(11): 2549-2568.
- [9] 罗宏林,柏林,侯东明,等.有限变工况特征迁移学习方法及其在高速列车轴箱轴承故障诊断中的应用[J].仪器仪表学报,2022,43(3):132-145.
LUO H L, BO L, HOU D M, et al. A transfer learning method for bearing fault diagnosis under finite variable working conditions and its application in train axle-box bearings fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 132-145.
- [10] 周长巍,李国勇,任蜜蜂,等.基于区分性联合概率分布的域适应故障诊断[J].振动与冲击,2023,42(7):170-179.
ZHOU CH W, LI G Y, REN M F, et al. Domain adaption fault diagnosis based on discriminative joint probability distribution difference [J]. Journal of Vibration and Shock, 2023,42(7): 170-179.
- [11] LIU S C, WANG H J, TANG J P, et al. Research on fault diagnosis of gas turbine rotor based on adversarial discriminative domain adaption transfer learning[J]. Measurement, 2022, 196: 111174.
- [12] HIEU C P, ASHUTOSH S D, NANG D B. Reliability assessment of pipelines crossing strike-slip faults considering modeling uncertainties using ANN models [J]. Reliability Engineering and System Safety, 2023, 237: 1-13.
- [13] LI W H, HUANG R Y, LI J P, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges [J]. Mechanical Systems and Signal Processing, 2022, 167: 108487.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 27(6):436-444.
- [15] FANG X, GONG G, LI G, et al. A hybrid deep transfer learning strategy for short term cross-building energy prediction [J]. Energy, 2021,

215: 119208.

E-mail: 1321604453@qq.com

作者简介

陈彬强(通信作者), 副教授, 主要研究方向为结构健康监测、机械故障诊断、人工智能及大数据处理。

林俊泽, 硕士研究生, 主要研究方向为管道故障诊断与系统开发。

E-mail: cbq@xmu.edu.cn