

引用格式:

郭建政, 童成彪. 基于深度卷积神经网络的单向阀泄漏模式识别[J]. 湖南农业大学学报(自然科学版), 2024, 50(2): 100–104.

GUO J Z, TONG C B. One-way valve leakage pattern recognition based on deep convolution neural network[J]. Journal of Hunan Agricultural University(Natural Sciences), 2024, 50(2): 100–104.

投稿网址: <http://xb.hunau.edu.cn>



基于深度卷积神经网络的单向阀泄漏模式识别

郭建政¹, 童成彪^{2*}

(1.湖南农业大学机电工程学院, 湖南 长沙 410128; 2.智能农机装备湖南省重点实验室, 湖南 长沙 410128)

摘要: 以 SV10PB1–30B 液控单向阀为研究对象, 利用传感器采集 3 种不同泄漏模式下 10 个阀芯的振动信号, 设计深度卷积模型, 开展不同测点(单向阀的上表面和阀座)、不同信号特征提取方式(原始信号、特征值、特征图)下的模式识别研究。结果表明: 基于轴向冲击信号特征值和深度卷积神经网络的模型能有效识别故障类型, 验证集上的识别准确率高达 88.293%, 是基于特征图的 7.79 倍, 是基于原始时域冲击信号的 1.16 倍; 训练步数以 100 的较优, 同时该模型对正常阀芯和不同损伤阀芯的分类效果明显。

关键词: 单向阀; 深度卷积神经网络; 故障诊断; 模式识别

中图分类号: TH137.52

文献标志码: A

文章编号: 1007–1032(2024)02–0100–05

One-way valve leakage pattern recognition based on deep convolution neural network

GUO Jianzheng¹, TONG Chengbiao^{2*}

(1.College of Mechanical and Electrical Engineering, Hunan Agricultural University, Changsha, Hunan 410128, China;
2.Key Laboratory of Intelligent Agricultural Machinery Equipment of Hunan Province, Changsha, Hunan 410128, China)

Abstract: In SV10PB1–30B hydraulic control check valve, the sensor was used to collect the vibration signals of 10 valve cores in 3 different leakage modes. A deep convolution model and pattern recognition test were performed with different measuring points(upper surface and seat of check valve) and different signal feature extraction methods(original signal, eigenvalue, feature map). The results showed that the fault type could be effectively identified, and the recognition accuracy rate on the verification set was as high as 88.293% with eigenvalues of the axial impact signal and the deep convolutional neural network. The accuracy was 7.79 times based on the feature map and 1.16 times based on the original time domain impact signal. The optimal number of training steps was 100. The model showed optimal classification effects on normal spool and different damaged spool.

Keywords: check valve; deep convolution neural network; fault diagnosis; pattern recognition

单向阀因其结构简单、便于更换等优点, 常应用于液压系统中, 起着防止液压油反向流动和保压等作用^[1]。由于制造加工水平的参差不齐, 有时会出现阀芯偏心、表面磨损等问题, 导致单向阀出现泄漏, 影响机械的正常运转。在日常生产中, 将单向阀拆卸后再对其进行检查往往很难准确定位故障,

停机时间较长, 这就需要利用传感器等设施对其故障信号进行检测、采集, 再通过分析故障信号来识别泄漏模式, 从而减少停机检测的次数和时间。如何在极低信噪比情况下实现泄漏模式的准确识别与泄漏量预测, 且要求检测方法和模型具有较好的泛化能力, 成为研究的难点。

收稿日期: 2023–01–10

修回日期: 2024–04–15

基金项目: 湖南省重点研发计划项目(2022NK2028); 湖南省自然科学基金项目(2020JJ4045)

作者简介: 郭建政(1998–), 男, 山东临清人, 硕士研究生, 主要从事机械故障诊断与智能控制研究, guojianzheng@163.com; *通信作者, 童成彪, 博士, 教授, 主要从事机械动力学与故障诊断研究, tongcb@163.com

深度卷积神经网络对局部特征的提取能力十分突出，因而将深度卷积神经网络和故障诊断结合的研究较多，研究热点大多集中在齿轮箱^[2-5]和轴承^[6-9]上。不同于轴承和齿轮的故障信号，出现故障的单向阀的脉冲信号不具有周期性，研究难度相对较大。ZHOU 等^[10]和 YUAN 等^[11]均以矿浆管道中的隔膜泵单向阀作为研究对象，采集其故障信号，分别采用不同的信号处理方法提取故障特征，并结合不同的机器学习方法对故障类型进行分类，较好地克服了故障的单向阀脉冲信号非线性的问题，取得了较为满意的识别效果。冯泽仲等^[12]采集矿浆管道中的隔膜泵单向阀的故障信号，在深度卷积之前先将原始信号进行循环频谱相干处理，使得信号特征表现明显，克服了传统特征提取方法的弊端，其识别正确率高达 98.13%。熊力等^[13]采用 EEMD 算法，提取振动故障信号和压力故障信号的特征值，结合粒子群算法优化支持向量机进行单向阀的故障识别，基于振动信号的识别准确率达 70%，识别效果还有一定的上升空间。TONG 等^[14]采用神经网络和冲击信号增强信号特征相结合的方法，取得了良好的单向阀泄漏模式识别效果。

笔者以 SV10PB1-30B 液控单向阀为研究对象，基于 RCYCS-G 液压系统故障实验台和 LabVIEW 软件对其故障信号进行采集，分别利用原始时域冲击信号、特征值、特征图等 3 种不同的信号形式，采用深度卷积神经网络对其故障模式进行识别，以期为单向阀的故障诊断提供依据。

1 信号采集

采用 RCYCS-G 液压系统故障实验台收集不同阀芯、不同工况下的故障信号。利用文献[14]的试验台，根据单向阀的泄漏机理^[15]设置 3 种不同的故障形式，每种故障类型各设置 3 个不同程度的阀芯，所用阀芯分类与标号如表 1 所示。

表 1 供试阀芯类别

Table 1 Valve spool category

标号	阀芯类别	标号	阀芯类别
0	正常	5	中度损伤
1	粗糙度 3.2	6	严重损伤
2	粗糙度 6.3	7	偏心 0.05 mm
3	粗糙度 12.5	8	偏心 0.10 mm
4	轻微损伤	9	偏心 0.20 mm

为保证振动信号和压力信号采样精度，试验开始前调整实验平台的砝码数量改变负载压力，同时将溢流阀的系统压力调至 8.5 MPa，在此工况压力下分别采集 10 个阀芯的振动、压力、位移、温度信号，每个阀芯重复做 60 次试验，共采集 600 组试验数据。数据采集系统由 NI PXIe-1062Q 数据采集箱、NI PXIe-8840 控制器、NI PXIe-4492 数据采集模块和振动传感器、LABVIEW 软件等构成。其中 2 个振动传感器均采用东华测试的 IEPE 压电式加速度传感器，型号为 1A113E，轴向灵敏度为 516.558 mV/g，量程为 ±10 g，分辨率为 0.000 04 g，采样频率设置为 2 kHz。2 个振动传感器分别安放在单向阀的上表面和单向阀的阀座上，安放位置如图 1 所示。采集到的某一阀芯的振动原始信号时域图如图 2 所示。



图 1 传感器布置

Fig.1 Sensor layout

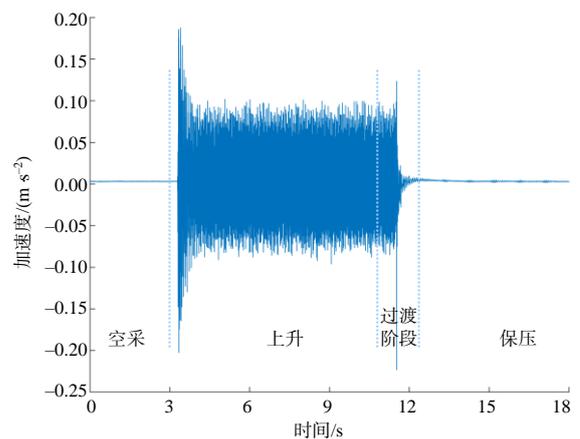


图 2 振动原始信号的时域

Fig.2 Time domain diagram of the original vibration signal

每次抬升试验共分 4 个阶段：第 1 阶段为信号空采阶段；第 2 阶段为试验平台抬升阶段，此阶段需启动电动机，因而振动信号中包含了电动机的干扰频率，故不采用此段信号；第 3 阶段为过渡阶段，即如图 3 所示信号冲击部分，这段信号包含故障特征信息，选取此段时间间隔为 2 s 的信号为研究对

象；第 4 阶段为保压阶段，此阶段试验平台处于最高位，但此时测到的信号较为微弱，故不采用此段信号。将上述第 3 阶段的冲击信号按规定命名之后整理为数据集，并按照 7 : 3 的比例随机划分成训

练集和验证集。

2 深度卷积神经网络

采用 Google 公司的深度学习框架 Tensorflow。计算机配置为 CPU i5 12400F, 16 GB 内存；显卡为 GTX1660Ti 6G。运用 Python 在 Tensorflow 环境下搭建深度卷积神经网络模型。

参照文献[12]的方法建立深度卷积神经网络模型。该模型包含 5 个卷积层、5 个池化层以及 1 个全连接层。卷积层激活函数采用不会出现梯度弥散现象的 ReLu 函数^[16]，使用 softmax 分类器进行分类。学习率^[17]均设置为 0.000 1，采用 Adam 优化器进行优化，categorical_crossentropy 作为损失函数，epoch 为 100。以长度为 4 000 的信号为例，深度卷积模型如图 4 所示。

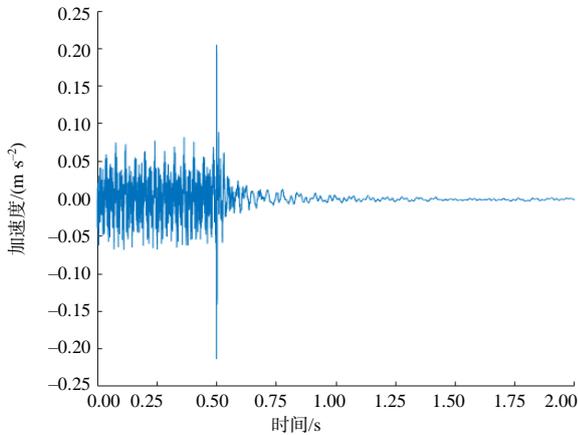


图 3 测点振动冲击信号

Fig.3 Measuring point vibration shock signal

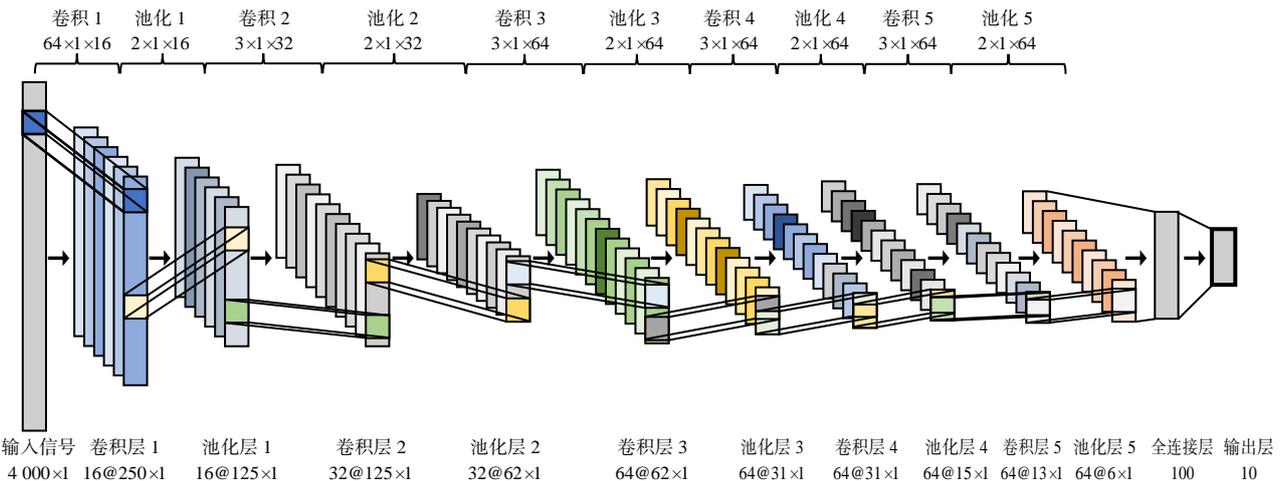


图 4 深度卷积神经网络模型

Fig.4 Deep convolutional neural network model diagram

3 泄漏模式识别

3.1 信号有效性

将截断后的振动冲击信号输入到深度卷积神经网络模型中进行训练，将单向阀上表面和单向阀阀座上的传感器信号分别标记为 V1、V2。为验证某一类或某几类信号对模型识别率的影响，将 V1、V2 及两者混合依次放进模型中进行 20 次独立试验，识别的正确率分别为(56.322±3.411)%、(75.321±0.451)%、(54.361±1.533)%。可见，使用 V2 信号时，识别率比其他 2 种情况的高，说明 V2 信号单独使用能提高该模型的识别率；因此，选取 V2 振动信

号，分别采用该信号的原始信号、特征值、特征图等 3 种形式的信号输入到模型中进行训练。

3.2 基于不同信号形式的模式识别

取 V2 信号作为输入信号，将图 3 中信号长度为 4 000 的原时域信号、采用 Dmey 小波基变换提取的冲击信号特征值、原振动冲击信号特征值转换成的如图 5 所示的特征图等 3 种形式的信号分别作为模型的输入层，各进行 20 次独立试验。为了使模型快速收敛^[18]，将特征值进行归一化处理；特征图像大小为 30 像素×30 像素。

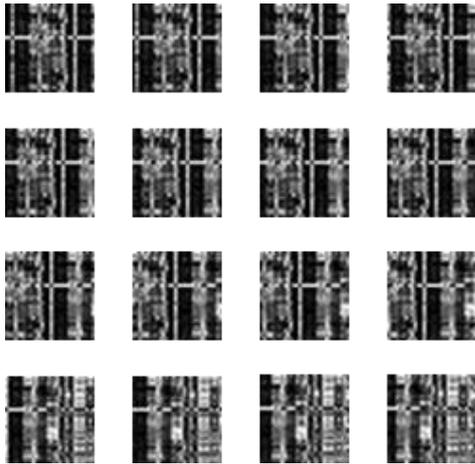


图 5 部分原振动冲击信号特征值转换成的特征图
Fig.5 Feature maps converted into the eigenvalues of part of the original vibration shock signal

结果显示,在进行训练时,基于原始时域冲击信号的模型识别率基本维持在 75%左右,最高可达 76.8%,在验证集上的识别率最高可达 77.2%;基于特征值模型的训练集和验证集的识别率均较高,且训练结果的方差较小,识别结果较为理想;基于特征图模型的识别率基本维持在 15%以下,识别效果极差,将特征值转成特征图的方法并不可行。验证集识别率和损失值分别如图 6 和图 7 所示,由图 6 和图 7 可知,输入特征值到深度卷积神经网络模型所得到的模式识别率明显高于其他 2 种形式的,损失值低于其他 2 种形式的。训练集和验证集平均识别率及平均训练时间如表 2 所示。由表 2 可知,在验证集中,基于特征值的识别率为基于特征图的 7.79 倍、基于原始时域冲击信号的 1.16 倍。可见,将原始信号提取特征值之后再输入到深度卷积神经网络模型所得到的模式识别率明显增加,而将特征值转换为图片后再进行训练时,识别率又大大降

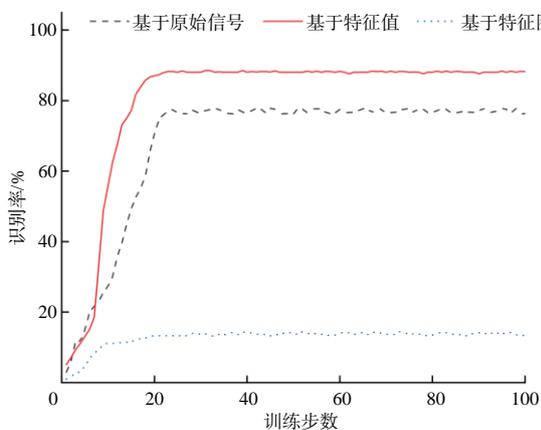


图 6 验证集的识别率
Fig.6 Accuracy of verification set

低,可能是在转成图片过程中出现了失真的现象,从而导致模型在识别特征信息时出现错误,最终导致模型故障类别识别率降低。

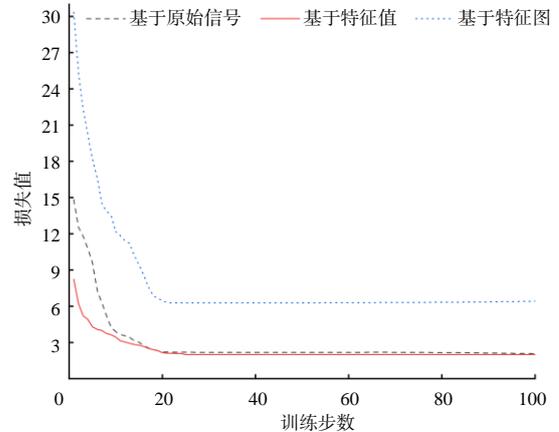


图 7 验证集的损失值
Fig.7 Loss of verification set

表 2 不同形式信号模式识别的训练结果

Table 2 Pattern recognition results based on the original signal

信号形式	识别率/%		平均训练时间/s
	训练集	验证集	
原始信号	75.144 ±4.231	76.001 ±4.503	34.292
特征值	99.512 ±0.253	88.293 ±0.531	34.301
特征图	13.124 ±2.331	11.341 ±2.013	34.924

3.3 训练步数对识别率的影响

为验证训练步数对识别率的影响,将 3 种轴向冲击信号输入方式的训练步数均设置 50、100、150、200 进行试验,其验证集上的识别率如图 8 所示。通过对比 3 条折线可以发现,训练步数不同时,其所对应的识别率有所不同,训练步数越多,识别率不一定会增加,模型的最优步数为 100。

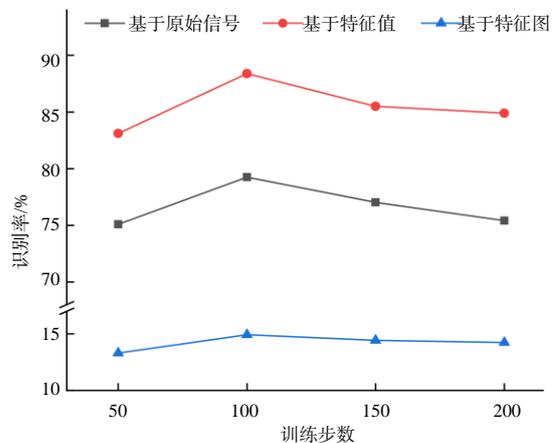


图 8 不同训练步数验证集的识别率
Fig.8 Accuracy of verification set with different steps

3.4 模型的分类情况

混淆矩阵可以清晰地展示出模型的分类情况^[19], 图 9-a、9-b、9-c 分别是以原始信号、特征值、特征图作为输入得出的混淆矩阵。图 9-a、9-b、9-c 分别是以原始信号、特征值、特征图作为输入得出的混淆矩阵。从图 9-a 和图 9-b 可知, 该模型对正常阀

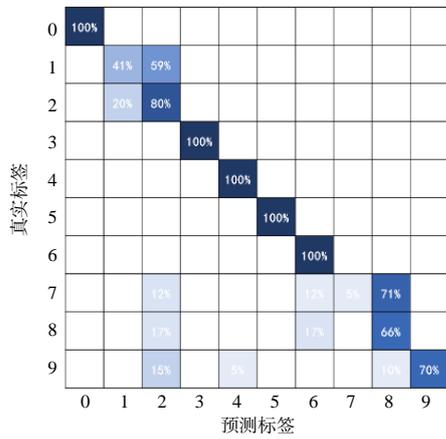
芯和不同损伤阀芯的分类效果明显, 且该模型极易将粗糙度 3.2 的阀芯分类成粗糙度 6.3 的阀芯; 从图 9-c 可知, 该模型以特征图作为输入信号的识别效果很差。

4 结论

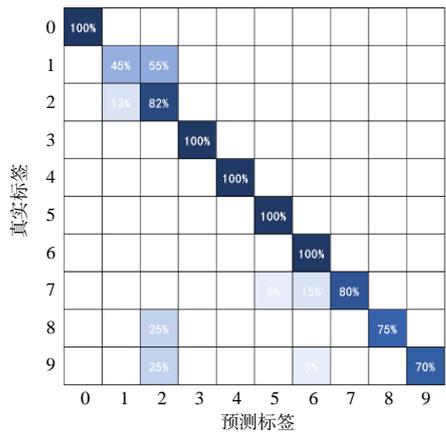
笔者以 SV10PB1-30B 液控单向阀为研究对象, 运用深度卷积神经网络模型对单向阀的泄漏模式进行识别, 并对 3 种轴向冲击信号输入方式(原始信号、特征值、特征图)进行了研究, 验证集上基于特征值的识别率最高, 可达 88.293%, 训练步数以 100 的较优, 同时该模型对正常阀芯和不同损伤阀芯的分类效果明显。后续将进行提高模型鲁棒性的研究, 并将模型应用于其他类型阀门泄露的识别。

参考文献:

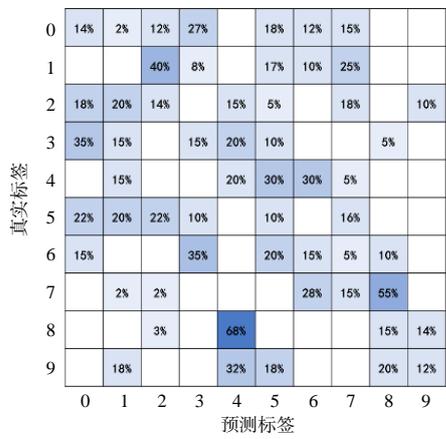
- [1] SCHICKHOFER L, WIMMER J. Fluid-structure interaction and dynamic stability of shock absorber check valves[J]. Journal of Fluids and Structures, 2022, 110: 103536.
- [2] OH Y, KIM Y, NA K, et al. A deep transferable motion-adaptive fault detection method for industrial robots using a residual-convolutional neural network[J]. ISA Transactions, 2022, 128: 521-534.
- [3] KAVIANPOUR M, GHORVEI M, KAVIANPOUR P, et al. An intelligent gearbox fault diagnosis under different operating conditions using adversarial domain adaptation[C]//2022 8th International Conference on Control, Instrumentation and Automation(ICCIA). Tehran, Iran: IEEE, 2022: 1-6.
- [4] GROVER C, TURK N. A novel fault diagnostic system for rolling element bearings using deep transfer learning on bispectrum contour maps[J]. Engineering Science and Technology, an International Journal, 2022, 31: 101049.
- [5] JUNIOR R F R, DOS SANTOS AREIAS I A, CAMPOS M M, et al. Fault detection and diagnosis in electric motors using 1d convolutional neural networks with multi-channel vibration signals[J]. Measurement, 2022, 190: 110759.
- [6] 卞景艺, 刘秀丽, 徐小力, 等. 基于多尺度深度卷积神经网络的故障诊断方法[J]. 振动与冲击, 2021, 40(18): 204-211.
- [7] AKHENIA P, BHAVSAR K, PANCHAL J, et al. Fault severity classification of ball bearing using SinGAN and deep convolutional neural network[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2022, 236(7): 3864-3877.



a



b



c

a、b、c 分别基于原始信号、特征值、特征图。

图 9 基于不同形式信号的验证集的混淆矩阵

Fig.9 Verification set confusion matrix based on feature map

(下转第 126 页)

- 2022, 26(6): 1431–1449.
- [17] 尹成祥, 张宏军, 张睿, 等. 基于加权距离的局部离群点检测算法[J]. 科学技术与工程, 2014, 14(15): 79–82.
- [18] PARK J, SHIN H. Vascular aging estimation based on artificial neural network using photoplethysmogram waveform decomposition: retrospective cohort study[J]. JMIR Medical Informatics, 2022, 10(3): e33439.
- [19] 赵雪, 顾伟红. 基于 GRA-SSA-Elman 的隧洞 TBM 掘进适应性评价[J]. 隧道建设(中英文), 2022, 42(11): 1879–1888.
- [20] MALIK S, ALI KHAN K, NOSHEEN A, et al. Generalization of Montgomery identity via Taylor formula on time scales[J]. Journal of Inequalities and Applications, 2022, 2022: 24.
- [21] 林小雨, 江岳文, 温步瀛. 基于逼近和牛顿插值法的最佳风电接纳水平确定[J]. 电力系统保护与控制, 2015, 43(18): 12–17.
- [22] 李佳园, 李耀南, 惠继录. 灰狼优化算法的应用综述[J]. 数字技术与应用, 2022, 40(9): 10–13.
- [23] 王玉芳, 曾亚志, 蒋亚飞. 基于自适应灰狼优化算法的柔性作业车间调度问题[J]. 现代制造工程, 2022(7): 1–10.
- [24] DAS D, KAYAL P, MAITI M. A K-means clustering model for analyzing the Bitcoin extreme value returns[J]. Decision Analytics Journal, 2023, 6: 100152.
- [25] 张忠平, 刘伟雄, 张玉停, 等. ERDOF: 基于相对熵权重密度离群因子的离群点检测算法[J]. 通信学报, 2021, 42(9): 133–143.

责任编辑: 邹慧玲

英文编辑: 柳正

(上接第 104 页)

- [8] HAKIM M, OMRAN A A B, AHMED A N, et al. A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: taxonomy, overview, application, open challenges, weaknesses and recommendations[J]. Ain Shams Engineering Journal, 2023, 14(4): 101945.
- [9] GUNDEWAR S K, KANE P V. Bearing fault diagnosis using time segmented Fourier synchrosqueezed transform images and convolution neural network[J]. Measurement, 2022, 203: 111855.
- [10] ZHOU C J, MA J, WU J D. Fault diagnosis of check valve based on CEEMD compound screening, BSE and FCM[J]. IFAC-PapersOnLine, 2018, 51(21): 323–328.
- [11] YUAN X Y, FAN Y G, ZHOU C J, et al. Fault diagnosis of check valve based on KPLS optimal feature selection and kernel extreme learning machine[J]. Coatings, 2022, 12(9): 1320.
- [12] 冯泽仲, 熊新, 王晓东. 基于循环频谱相干和 DCNN 的隔膜泵单向阀故障诊断方法研究[J]. 振动与冲击, 2021, 40(14): 237–244.
- [13] 熊力, 刘宁, 童成彪, 等. 单向阀微弱内泄漏故障特征提取与模式识别研究[J/OL]. 机械科学与技术: 1–9. (2022–11–08)[2022–12–04]. <https://doi.org/10.13433/j.cnki.1003-8728.20220293>.
- [14] TONG C B, SEPEHRIN, ZHOU J. Root cause detection of leakage in check valves using multi-scale signal analysis[J]. Journal of Mechanical Science and Technology, 2023, 37(1): 55–67.
- [15] 梁立民. 液压系统的泄漏及其防治[J]. 同煤科技, 2013(4): 38–40.
- [16] 肖雄, 王健翔, 张勇军, 等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558–4568.
- [17] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300–1312.
- [18] 刘建伟, 赵会丹, 罗雄麟, 等. 深度学习批归一化及其相关算法研究进展[J]. 自动化学报, 2020, 46(6): 1090–1120.
- [19] 陆克中, 陈超凡, 蔡桓, 等. 面向概念漂移和类不平衡数据流的在线分类算法[J]. 电子学报, 2022, 50(3): 585–597.

责任编辑: 邹慧玲

英文编辑: 柳正