

多子阵声信号融合下轴向柱塞泵故障智能识别方法*

王长林^① 孙俊杰^② 钟永腾^②

(^①江苏开放大学信息工程学院, 江苏 南京 210003; ^②温州大学机电工程学院, 浙江 温州 325035)

摘要: 利用非接触式声阵列构造了多个子阵, 建立了轴向柱塞泵故障噪声信号监测模型, 并基于卷积神经网络-支持向量机(**convolutional neural network-support vector machine, CNN-SVM**) 组合模型提出了故障智能识别方法。首先, 运用子阵列平移的信号模型进行信号滤波, 结合小波变换(**continuous wavelet transform, CWT**) 生成时频图样本, 通过多子阵合成 **RGB** 图片作为故障声信号样本; 其次, 用 **SVM** 替代 **Softmax** 分类器, 建立了基于 **CNN-SVM** 的多子阵声信号融合的故障识别模型; 最后, 设计了柱塞故障、配流盘故障、斜盘故障和回程盘故障等 4 种故障并进行了实验验证。结果表明, 所提方法在运行噪声环境下的分类准确率达到 97.5%, 相较于单通道时频样本, 其准确率提高了 1.1%。

关键词: 声信号; 小波变换; **RGB**; **CNN-SVM** 模型; 故障识别

中图分类号: **TP23** 文献标识码: **A**

DOI: [10.19287/j.mtmt.1005-2402.2024.09.003](https://doi.org/10.19287/j.mtmt.1005-2402.2024.09.003)

Fault intelligent identification method for axial piston pump using multi-subarray acoustical signal

WANG Changlin^①, SUN Junjie^②, ZHONG Yongteng^②

(^①School of Information Technology, Jiangsu Open University, Nanjing 210003, CHN; ^②School of Mechanical and Electrical Engineering, Wenzhou University, Wenzhou 325035, CHN)

Abstract: A fault noise signal monitoring model of axial piston pump is established by using non-contact acoustic array, and an intelligent fault identification method is proposed based on CNN-SVM model. Firstly, the signal model of subarray translation is used to filter the signal, and the time-frequency graph sample is generated by continuous wavelet transform (CWT). RGB picture is synthesized by multiple subarrays as the fault acoustic signal sample. Secondly, the fault identification model of multi-subarray acoustic signal fusion based on CNN-SVM is established using SVM replaced Softmax classifier. Finally, four kinds of faults such as plunger fault, plate fault, swash plate fault and return plate fault are designed and verified by experiments. The results show that the classification accuracy of the proposed method reaches 97.5% in the running noise environment, which is 1.1% higher than that of the single channel time-frequency sample.

Keywords: acoustical signal; CWT; RGB; CNN-SVM model; fault identification

泵作为液压系统中应用最广泛的部件之一, 已广泛应用于机床设备。它具有较高的功率密度、较高的极限压力和较长的使用寿命等优点^[1]。然而, 泵长期在高速、高压的恶劣环境下工作, 导致其内部关键零部件疲劳失效, 从而引起局部故障问题的出现^[2]。

近年来故障诊断技术发展迅速, 不少学者基于柱塞泵振动信号和压力信号等提出了液压泵故障诊断的方法。陈俊柏等^[3]采集燃油泵出口处的振动与压力信号, 结合机器学习研究了故障识别方法。Wang J P 等^[4]采集油田采油用泵上的振动信号, 运用模糊逻辑方法, 研究了对不同泵故障谱的分类和

* 国家自然科学基金青年科学基金资助项目(51505339); 浙江省自然科学基金青年基金资助项目(LQ16E050005)

状态识别方法。Yuan X L 等^[5]通采集外壳体上不同故障下振动信号,结合经验模态分解、自回归谱能和小波核极限学习机研究了柱塞泵轴向的故障识别。Chen Y F 等^[6]采用马氏距离代替传统 KNN 算法中的距离函数,在实验数据不平衡的状态下有效提高了离心泵故障识别准确率。Xia S Q 等^[7]基于振动信号建立了 OAA-SSVM 模型的柱塞泵故障识别方法。Muralidharan V 等^[8]通过计算振动信号的小波特征,并结合模糊逻辑对离心泵故障进行分类。Liu X L 等^[9]计算柱塞泵不同故障状态下振动信号复合多尺度熵,通过核极限学习机进行了柱塞泵故障识别。

随着计算机技术的快速发展,神经网络模型逐步应用于故障诊断方法中。焦瀚晖等^[10]对输入卷积神经网络的一维振动信号进行快速构造,加快模型收敛,提高了泵的故障识别准确率。Zhu Y 等^[11]通过改进标准 LeNet-5 中的卷积核大小与数量,并通过粒子群算法优化模型超参数,提高了轴向柱塞泵故障分类精度。Yan J Y 等^[12]建立一维卷积神经网络,提高了泵故障识别准确率。Wang S H 等^[13]通过 DBN (深度置信网络) 对其进行分类,提高了泵故障分类精度。Samanipour P 等^[14]运用自组织映射神经网络,有效地监测泵的早期空化现象。Chao Q 等^[15]通过梯度-凸轮热图图像处理方法去除频谱图中的夹带噪声,增强了图像特征,提高了卷积神经网络模型在噪声环境下的识别性能。徐昌玲等^[16]搭建了一维卷积神经网络 (1D convolutional neural network, 1D-CNN), 自适应地从时域振动信号中提取数据特征,实现了柱塞泵故障高精度分类。Bie F F 等^[17]通过长短期记忆深度神经网络提取往复泵振动信号的故障特征,提高了故障识别准确率。

上述研究大多采用了接触式传感器,对于结构紧凑的轴向柱塞泵来说,非接触式的传感器可以避免其安装空间的限制,便于安装和操作。麦克风作为非接触式传感器之一,在泵的故障监测中具有较好的应用前景。液压系统运行的过程中含有大量的噪声,当柱塞泵某些关键零部件发生故障时,噪声中可能包含大量的故障信息。本文采用自制声阵列研究了多子阵声信号融合下轴向柱塞泵故障智能识别方法。首先,运用子阵平移的信号模型,结合小波变换建多子阵故障声信号样本;其次,用 SVM 替代 Softmax 分类器,建立了基于 CNN-SVM 的多子阵声信号融合的故障故障识别模型;最后,设计

了柱塞故障、配流盘故障、斜盘故障和回程盘故障等 4 种故障并进行了实验验证。

1 多子阵故障声信号样本构建

图 1 所示为阵列信号接收模型,相邻传感器横向间距为 d ,当方位角 θ 声源入射到传感器阵列时,阵元 i 接收信号相对于参考阵元 0 的波程差为 $id \cos \theta$ 。定义的导向矢量 $\mathbf{a}(\theta)$ 如下:

$$\mathbf{a}(\theta) = [e^{-j\omega\tau_{-M}}, \dots, 0, e^{-j\omega\tau_i}, \dots, e^{-j\omega\tau_M}] \quad (1)$$

式中: j 为复指数; τ_M 为阵元 M 的时间延迟; τ_{-M} 为阵元 $-M$ 的时间延迟; τ_i 为阵元 i 的时间延迟; ω 为信号角频率。

τ_i 信号之间的时间延迟为

$$\tau_i = id \cos \theta / c \quad (2)$$

式中: d 为传感器间距; c 为传播速度。

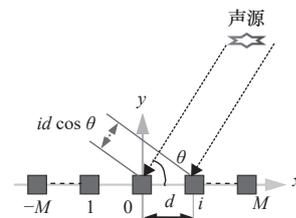


图 1 阵列信号模型

因此,不同方向的声源信号具备不同的导向矢量,可达到空滤滤波的效果。当轴向柱塞泵中关键零部件发生故障时会产生异常噪声,设置麦克风传感器阵列可有效获取因故障产生的辐射噪声,通过辐射噪声对其进行故障识别。然而,因为其他噪声源的存在,尤其相干噪声源的存在,影响了故障噪声定位。图 2 所示为多麦克风传感器子阵信号监测模型,包含了组成线型阵列的 9 个麦克风传感器,其编号为 C1~C9。为了消除相干噪声的影响,通过平移得到 p 个相互交错的子阵列,每个子阵列的阵元数为 m 。

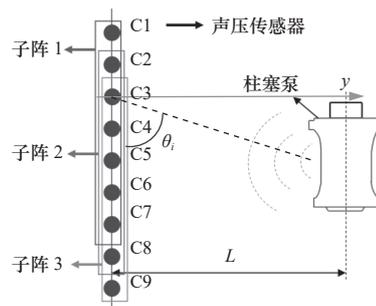


图 2 轴向柱塞泵多子阵信号监测模型

C1~C7 组成子阵 1, 以其为参考子阵, 则子阵 1 中阵元 l 接收的信号数据为

$$x_l(t) = \sum_{i=1}^N \mathbf{a}_i(\theta_i) s_i(t) + n_l(t), l = 1, 2, \dots, 7 \quad (3)$$

式中: N 为信号源数; $x_l(t)$ 为阵元 l 接收信号; \mathbf{a}_i 为导向矢量; θ_i 为信号入射角度; $s_i(t)$ 为源信号; $n_l(t)$ 为噪声信号。

均匀线阵中子阵平移因子 β_i 为

$$\beta_i = 2\pi f \tau_{li} \quad (4)$$

式中: f 为信号频率; τ_{li} 为子阵阵元 i 的时间延迟。

第 p 个子阵的数据模型为

$$\mathbf{x}_p(t) = [x_p, x_{p+1}, \dots, x_{p+m+1}] = \mathbf{A} \mathbf{D}^{p-1} \mathbf{s}(t) + \mathbf{n}_p(t) \quad (5)$$

其中,

$$\mathbf{D} = \begin{bmatrix} e^{j\beta_1} & 0 & 0 \\ 0 & e^{j\beta_2} & 0 \\ 0 & 0 & e^{j\beta_3} \end{bmatrix} \quad (6)$$

式中: \mathbf{A} 为导向矢量矩阵; \mathbf{D} 为子阵平移矩阵; $\mathbf{s}(t)$ 为源信号; $\mathbf{n}_p(t)$ 为子阵噪声信号。

于是子阵数据协方差矩阵 \mathbf{R}_p 为

$$\mathbf{R}_p = \mathbf{A} \mathbf{D}^{(p-1)} \mathbf{R}_s (\mathbf{D}^{(p-1)})^H \mathbf{A}^H + \sigma^2 \mathbf{I} \quad (7)$$

式中: \mathbf{R}_s 为协方差矩阵; \mathbf{A}^H 为导向矢量共轭转置; σ 为噪声功率; \mathbf{I} 为噪声协方差矩阵。

取前向平滑修正的协方差矩阵 \mathbf{R}^f 为

$$\mathbf{R}^f = \mathbf{A} \left(\frac{1}{P} \sum_{i=1}^P \mathbf{D}^{(k-1)} \mathbf{R}_s (\mathbf{D}^{(k-1)})^H \right) \mathbf{A}^H + \sigma^2 \mathbf{I} \quad (8)$$

根据上述理论, 定义如下矩阵:

$$\mathbf{Z}_p = [0_{m \times (p-1)} \mid \mathbf{I}_{m \times m} \mid 0_{m \times (P-p)}] \quad (9)$$

定义第 p 个子阵在 t 时刻的输出信号 $x_p(t)$, 具体如下:

$$\mathbf{x}_p(t) = [x_p, x_{p+1}, \dots, x_{p+m-1}] = \mathbf{Z}_p \mathbf{X}(t) \quad (10)$$

式中: $\mathbf{X}(t)$ 为整个阵列采集的响应信号。

$\mathbf{X}(t)$ 协方差可以表示为

$$\mathbf{R}_p = \mathbf{Z}_p \hat{\mathbf{R}} \mathbf{Z}_p^H \quad (11)$$

因此, 经过前向空间平滑算法得到的信号协方差为

$$\mathbf{R}_p = \frac{1}{P} \sum_{i=1}^P \mathbf{R}_p = \frac{1}{P} \mathbf{Z}_p \hat{\mathbf{R}} \mathbf{Z}_p^H \quad (12)$$

式中: $\hat{\mathbf{R}}$ 整个阵列响应信号的无偏估计; \mathbf{Z}_p^H 为数据矩阵共轭。

过一个设置好的滤波器, 滤波器的权值 \mathbf{w} 可以表示为

$$\mathbf{w} = [w_1, w_2, \dots, w_7]^T \quad (13)$$

式中: \mathbf{T} 表示矩阵的转置。

滤波后的信号 y 为

$$y = \mathbf{w}^H \mathbf{X} \quad (14)$$

滤波器的权值设计是输出功率最小化, 同时满足特征频率 f_c 处的响应具有单位增益, 这个约束为无失真响应约束, 即为

$$\mathbf{w}^H \mathbf{a}(\theta_{obj}(t)) = 1 \quad (15)$$

式中: $\mathbf{a}(\theta_{obj}(t))$ 为目标角度 θ 下的导向矢量。

数学上, 通过求解以下约束优化问题得到无失真响应滤波器, 具体见式 (16) 和式 (17)。

$$\begin{aligned} \mathbf{w}_{obj} &= \min \mathbf{w}^H \mathbf{R}_p \mathbf{w} \\ \text{subject to } & \mathbf{a}(\theta_{obj}(t), \varphi_{obj}(t)) = 1 \end{aligned} \quad (16)$$

式中: \mathbf{w}_{obj} 为目标权重。

这个约束优化问题的解为

$$\mathbf{w}_{obj} = \frac{\mathbf{R}_p^{-1} \mathbf{a}(\theta_{obj}(t))}{\mathbf{a}^H(\theta_{obj}(t)) \mathbf{R}_p^{-1} \mathbf{a}(\theta_{obj}(t))} \quad (17)$$

式中: \mathbf{H} 为共轭转置。

滤波后的信号表示为

$$y(i) = \mathbf{w}_{obj}^H(i) \mathbf{x} \mathbf{X}_p(t) \quad (18)$$

对 3 个子阵分别进行空域滤波, 运用 CWT 将其生成的时频图转为灰度图, 分别作为一张图片 RGB 三通道进行合成, 并将生成的数据集按照一定比例随机划分成训练集、验证集和测试集。

2 基于 CNN-SVM 的故障智能识别方法

由于输入的样本为二维 RGB 融合时频样本, 本文构建的 2D-CNN 模型主要包括输入层、卷积层、最大池化层和全连接层。本文将 64×64 像素的时频融合光谱图输入到输入层, 然后传输到卷积层和池化层用于自动提取特征图。

CNN 模型训练采用 ReLU 激活函数和 Adam 优化器, 学习率为 1×10^{-6} , 损失函数选择 cross entropy。同样采用径向基核函数 (radial basis function, RBF) 作为 SVM 的核函数, 其拥有的两个重要超参数 C 和 γ 对分类任务的结果有较大影响, 通过网格搜索算法对超参数 C 和 γ 进行全局寻优。柱塞泵故障识别流程如图 3 所示。

3 实验验证

图 4 所示为轴向柱塞泵故障模拟实验台, 实验台主要由电机和泵体组成。

实验所用泵型号为 25SCY14-1B, 测试台和信号采集系统如图 2 所示。实验模拟了轴向柱塞泵中

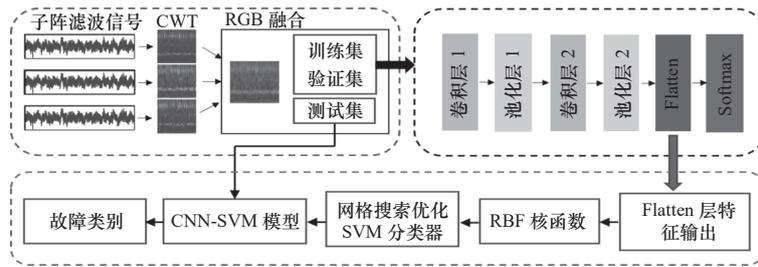


图3 柱塞泵故障识别的流程图

的4种故障，分别为柱塞故障（PF）、配流盘故障（VPF）、斜盘故障（SPF）和回程盘故障（RDF）。柱塞泵的故障实验均在15 MPa压力下完成，调整压力等待柱塞泵稳定运行并采集实验数据。Rhythm 64通道声阵列采集仪用于采集声信号。传感器之间距离为4 cm，离泵体旋转中心距离为0.7 m，声压传感器型号为ICS-40212，频响的范围为40~24 000 Hz，数据采集设备采样频率为48 828 Hz。

对比得到不同信号组合的RGB信号融合的预测准确率，具体结果见表1。子阵1与子阵2滤波后信号样本的分类准确率皆比阵中包含的传感器准确率高，子阵3滤波后信号样本分类准确率与包含的最高准确率的单传感器信号样本分类准确率一样高，这可以看出子阵空域滤波的有效性。此外，3个子

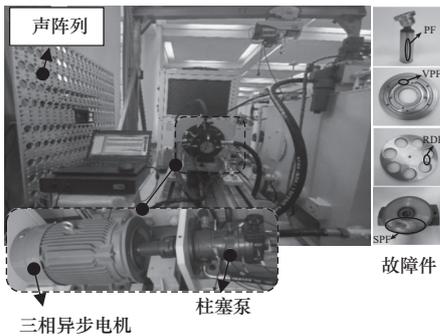
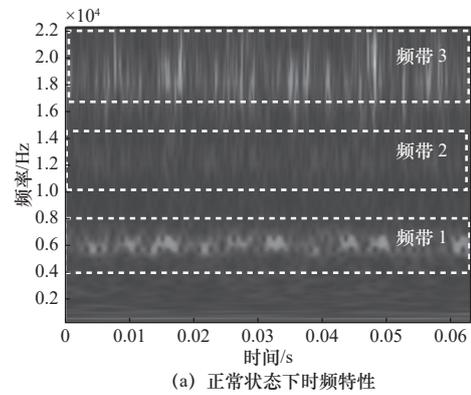


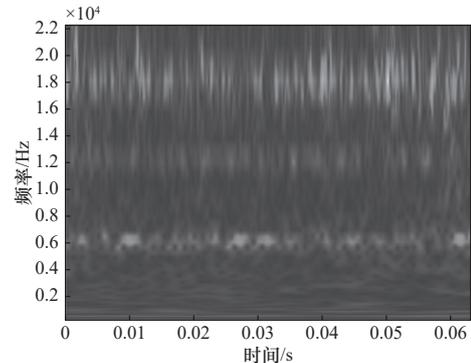
图4 轴向柱塞泵故障模拟实验台

对3个子阵分别进行空域滤波，并取时域信号的3 072数据点为1帧，相邻两帧有10%的重叠部分，将每类故障噪声数据分帧处理后得到200帧样本数据，分别采用CWT对每一帧进行时频信号分析。对柱塞泵不同故障状态下的时域信号进行连续小波变换，得到的不同故障工况下时频图对比如图5所示，频率能量集中在6、12以及18 kHz附近。相比较于正常状态下的时频谱图，柱塞故障、斜盘磨损、回程盘故障以及配流盘故障在这3个主频带附近的能量均有不同的变化，其他区域也有变化但没有主频带上的能量变化明显。最后，将其生成的时频图转为灰度图，分别作为一张图片RGB三通道进行合成，并将生成的数据集按照数量比例6:2:2随机划分成训练集、验证集及测试集，合成方法如图6所示。

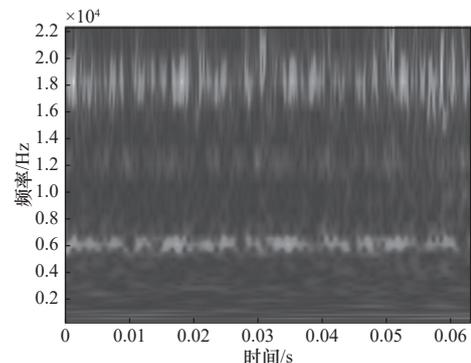
将C1~C9的单通道传感器采集的信号样本、子阵滤波信号以及子阵融合信号输入至CNN模型，



(a) 正常状态下时频特性



(b) 柱塞故障



(c) 斜盘磨损

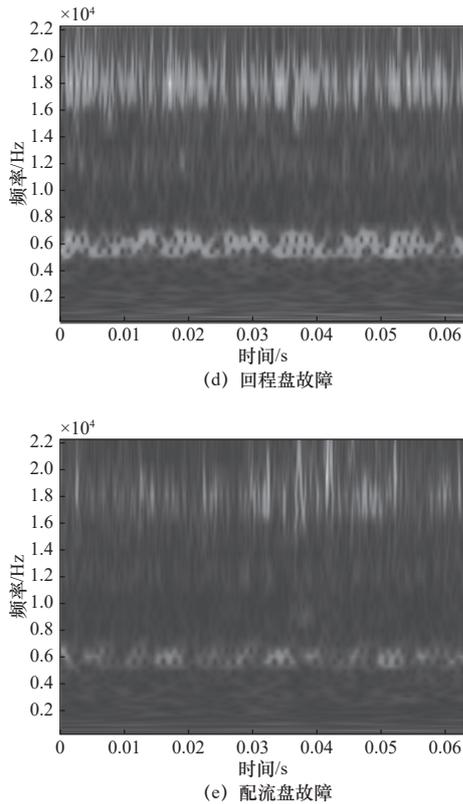


图5 不同故障工况下时频图对比

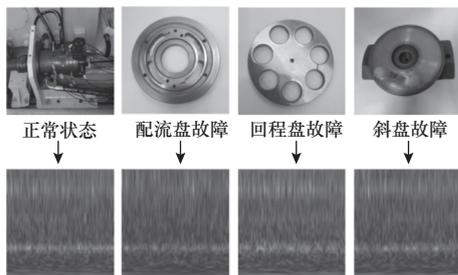


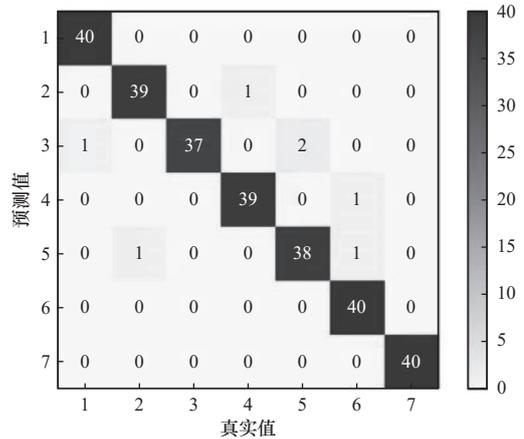
图6 不同故障 CWT 时频图融合样本

表1 不同信号组合的 RGB 信号融合的预测准确率对比

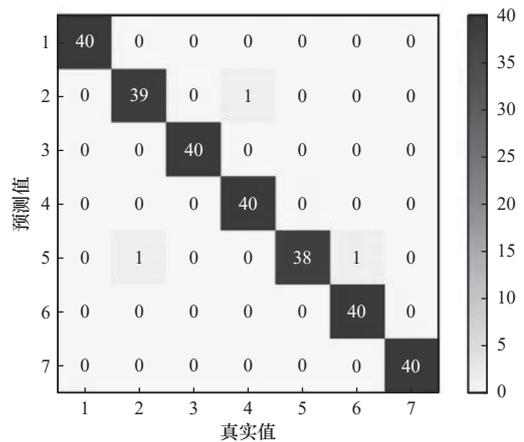
样本来源	传感器编号								
	C1	C2	C3	C4	C5	C6	C7	C8	C9
单传感器信号	92.5%	92.9%	95.7%	95.7%	95.0%	92.9%	87.5%	93.2%	96.4%
子阵1 (C1~C7)	96.4%								
子阵2 (C2~C8)		96.4%							
子阵3 (C3~C9)			95%						
多子阵融合	97.5%								

阵信号 CWT 时频融合样本作为样本后训练测试，准确率达到 97.5%，预测准确率相较于最高的单通道样本测试准确率高了 1.1%。

通过网格搜索算法确定 SVM 的超参数 $C=1$ 和 $\gamma=0.001$ 。通过对比图 7 两种模型的混淆矩阵可以看出，常用 CNN 模型采用 Softmax 分类器还是存在较多误判的情况，而使用 SVM 替换 Softmax 分类器的 CNN-SVM 模型具有相对更好的分类性能，分类精度提升了 1.42%。



(a) CNN-Softmax 混淆矩阵



(b) CNN-SVM 混淆矩阵

图7 CNN-Softmax 混淆矩阵与 CNN-SVM 混淆矩阵

4 结语

本文基于 CNN-SVM 模型提出了一种多子阵声信号融合下轴向柱塞泵故障智能识别方法，通过搭建柱塞泵故障模拟试验台对多提方法进行了验证，并得出以下结论：

(1) 通过多子阵平滑滤波得到的声信号通过 RGB 融合方法合成为新的样本，有效解决了单个传感器获取信息有限与预测稳定性问题。所提方法的故障识别精度相较于单传感器通道样本至少提高了 1.1%。

(2) CNN-SVM 模型相比较于普通的 CNN 模

型具有更好的泛化能力，因此表现出了更好的分类效果，在柱塞泵模拟实验样本中分类准确率达到97.5%，相较于CNN-Softmax模型有高的识别准确率。

参 考 文 献

- [1] 郭茜, 邹芳. 注塑机液压传动系统常见故障浅析 [J]. 制造技术与机床, 2020(10): 126-129.
- [2] 张兴军. 基于模糊理论的液压泵故障诊断专家系统软件的开发 [J]. 制造技术与机床, 2013(11): 139-141.
- [3] 陈俊柏, 刘勇智, 陈勇, 等. 基于EMD和SVM的机载燃油泵故障诊断研究 [J]. 北京航空航天大学学报, 2021, 47(8): 1687-1696.
- [4] Wang J P, Hu H T. Vibration-based fault diagnosis of pump using fuzzy technique[J]. *Measurement*, 2006, 39(2): 176-185.
- [5] Yuan X L, Kai J, Chen Y, et al. A support vector machine framework for fault detection in molecular pump[J]. *Journal of Nuclear Science and Technology*, 2022, 60: 72-82.
- [6] Chen Y F, Yuan J P, Luo Y, et al. Fault prediction of centrifugal pump based on improved KNN[J]. *Shock and Vibration*, 2021: 1-12.
- [7] Xia S Q, Zhang J H, Ye S G, et al. A spare support vector machine based fault detection strategy on key lubricating interfaces of axial piston pumps[J]. *IEEE Access*, 2019, 7: 178177-178186.
- [8] Muralidharan V, Sugumaran V. Rough set based rule learning and fuzzy classification of wavelet features for fault diagnosis of monoblock centrifugal pump[J]. *Measurement*, 2013, 46(9): 3057-3063.
- [9] Liu X L, Yang X Q, Shao F M, et al. Composite multi-scale basic scale Entropy based on CEEMDAN and its application in hydraulic pump fault diagnosis[J]. *IEEE Access*, 2021, 9: 60564-60576.
- [10] 焦瀚晖, 胡明辉, 王星, 等. 基于特征快速构造与卷积神经网络的机泵故障识别研究 [J]. 机电工程, 2020, 37(9): 1063-1068.
- [11] Zhu Y, Li G P, Wang R, et al. Intelligent fault diagnosis of hydraulic piston pump combining improved LeNet-5 and PSO hyperparameter optimization[J]. *Applied Acoustics*, 2021, 183: 108336.
- [12] Yan J Y, Zhu H J, Yang X Q, et al. Research on fault diagnosis of hydraulic pump using convolutional neural network[J]. *Journal of Vibroengineering*, 2016, 18(8): 5141-5152.
- [13] Wang S H, Xiang J, Zhong Y, et al. A data indicator-based deep belief networks to detect multiple faults in axial piston pumps[J]. *Mechanical Systems and Signal Processing*, 2018, 112: 154-170.
- [14] Samanipour P, Poshtan J, Sadeghi H. Cavitation detection in centrifugal pumps using pressure time-domain features[J]. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2017, 25(5): 4287-4298.
- [15] Chao Q, Wei X L, Tao J F, et al. Cavitation recognition of axial piston pumps in noisy environment based on Grad-CAM visualization technique[J]. *CAAI Transactions on Intelligence Technology*, 2022, 8(1): 206-218.
- [16] 徐昌玲, 黄家海, 兰媛, 等. 基于1D-CNN的轴向柱塞泵故障诊断研究 [J]. 机电工程, 2021, 38(11): 1494-1500.
- [17] Bie F F, Du T F, Lyu F, et al. An integrated approach based on improved CEEMDAN and LSTM deep learning neural network for fault diagnosis of reciprocating pump[J]. *IEEE Access*, 2021, 9: 23301-23310.

第一作者: 王长林, 男, 1983年生, 硕士, 讲师, 主要研究方向为目标检测。E-mail: wangcl@jsou.edu.cn

通信作者: 钟永腾, 男, 1984年生, 博士, 副教授, 硕士研究生导师, 主要研究方向为结构健康监测技术。E-mail: zhongyongteng@wzu.edu.cn

(编辑 曲书瑶)

(收修改稿日期: 2024-02-22)

文章编号: 20240906

如果您想发表对本文的看法, 请将文章编号填入读者意见调查表中的相应位置。

论文推荐

于俊甫, 于珍. 基于物料分类的差异化采购管理策略[J]. 制造技术与机床, 2022, (3): 162-165.



扫码获取全文

基于物料分类的差异化采购管理策略

于俊甫 于珍
山东大学机械工程学院

摘要 制造业企业物料种类繁多, 针对不同物料的采购管理问题, 基于Kraljic模型提出差异化采购管理策略。根据物料特性, 从利润影响和供应风险两个维度, 将物料分为战略物料、杠杆物料、非关键物料和瓶颈物料4类。从战略物料中再划分出供应风险极高的核心物料。分析各类物料特点, 提出相应的采购策略、供应商管理策略以及库存策略。通过精准的差异化采购管理, 实现保障物料供应稳定, 降低成本及供应风险的目的。

关键词 物料分类; 采购管理策略; Kraljic模型