

基于改进 EfficientNet 的抽油机井故障分级评价方法

李翔宇¹, 张 帅¹, 高宪文², 袁春华¹

(1. 沈阳理工大学 自动化与电气工程学院, 沈阳 110159; 2. 东北大学 信息科学与工程学院, 沈阳 110819)

摘要: 针对抽油机井电参数的特征提取及故障分级评价的准确性问题, 提出使用相对位置矩阵对抽油机井电参时序数据进行图像编码增强抽油机井电参数特征并生成抽油机井故障数据集的方法, 改进 EfficientNet 模型对抽油机井故障进行更加精确的分级评价。该方法对抽油机井电参数进一步处理并凸显其关键特征, 利用图像编码和深度学习技术提高抽油机井故障分级方法的准确性和效率。通过对典型故障的分级实验以及与多种模型性能的对比实验表明, 该方法在抽油机井故障分级评价中具有较高的准确性。

关键词: 抽油机井; 故障评价; 相对位置矩阵; 图像编码; EfficientNet

中图分类号: TP277 文献标志码: A DOI:10.3969/j.issn.1003-1251.2025.03.001

Fault Classification Evaluation Method of Pumping Unit Wells Based on Improved EfficientNet

LI Xiangyu¹, ZHANG Shuai¹, GAO Xianwen², YUAN Chunhua¹

(1. Shenyang Ligong University, Shenyang 110159, China; 2. Northeastern University, Shenyang 110819, China)

Abstract: The method is proposed to use a relative position matrix to encode the time-series data of electrical parameters of pumping unit wells into images, enhancing the feature extraction of these parameters, and generating a fault dataset for the pumping unit wells. The improved EfficientNet model is utilized for more accurate fault-level evaluation of the pumping unit wells. This approach further processes the electrical parameter data of the pumping unit wells and highlights its key features, leveraging image encoding and deep learning technologies to increase the accuracy and efficiency of fault-level evaluation in pumping unit wells. The results of experiments on typical faults and performance comparison experiments with various models indicate that this method exhibits high accuracy in fault-level evaluation of pumping unit wells.

Key words: pumping unit well; fault evaluation; relative position matrix; image encoding; EfficientNet

有杆泵抽油是国内外抽油机井广泛的采油方式之一, 在工作中易出现故障从而引发安全问题, 所以研究故障诊断方法^[1-2] 尤为重要。示功图方法^[3-5] 为主要故障诊断方法, 避免了传统动液面测量法必须停井测量的局限性, 但传感器安装和维护困难, 增加了整体的维护成本, 并且示功图对

井外的故障信息收集不够全面, 导致监测结果的局限性。因此, 利用电参数^[6] 进行故障诊断成为一种更为有效的方法。

抽油机井故障诊断^[7-8] 包含两个步骤: 特征提取与故障分类。Zheng 等^[9] 考虑了阀门工作点等关键参数, 从电机功率数据中提取 7 个特征对

有杆抽油泵建模和故障诊断。Zhang 等^[10]利用仿真模型生成抽油机井电机功率并通过生成的电功率数据对抽油机井进行诊断。李翔宇等^[11-12]提出了基于有杆泵抽油机井的动态机理,运用伯努利方程和物质平衡方程建立采油过程动态机理模型,通过改进变分模态分解特征提取方法对抽油机井进行诊断。但人为筛选的特征易受经验主义影响,基于深度学习的自动特征提取降低了专业知识依赖、提高了分析效率。He 等^[13]提出一种利用卷积神经网络与专家规则方法对抽油机井进行诊断。Wu 等^[14]通过迁移学习建立抽油机井故障诊断模型,使用全局池化层作为分类器,在数据样本不均匀情况下也能准确完成诊断任务。

尽管上述方法在抽油机井故障诊断方面取得了一定成果,但仍存在一些局限性。现有方法通常用于区分典型故障类型,而实际应用中的油井故障往往会经历多个复杂的发展阶段,存在多样性和动态性,使传统的故障诊断方法难以全面、准确地捕捉故障的全貌。

为进一步提升智能管理油井的效果,本文提出一种基于图像编码技术与深度学习方法相结合的故障评价与分析新策略。通过对抽油机井电参数进行图像化处理,将时间序列数据转换为二维图像,从而利用深度学习模型对图像进行深层次的提取和分析。该方法不仅可以更精确地识别不同类型的故障,还能捕捉到故障图中的程度差别,提供更加细致和全面的分级评价。

本文提出的抽油机井故障分级评价方法首先利用相对位置矩阵(relative position matrix, RPM)^[15]将一维电参数编码为二维图像,以便将抽油机井电参数应用于深度学习模型;其次,应用改进后的 EfficientNet 模型对油井常见的游动阀漏失和供液不足两种故障分别进行分类,实现精确的故障分级评价。

1 抽油机井故障分级评价框架

1.1 主要流程设计

本文改进 EfficientNet 抽油机井故障分级评价方法流程如图 1 所示,选择抽油机井电参工况数据为数据集。该框架包含 4 个部分:抽油机井工况数据收集、数据预处理、基于改进 EfficientNet 的抽油机井故障分级评价模型的训练和模型应用。

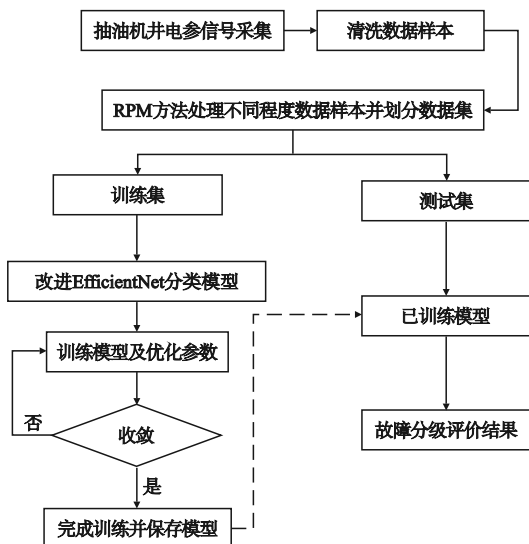


图 1 评价方法流程图

Fig. 1 Method flowchart

1.2 相对位置矩阵计算方法

RPM 旨在捕捉时间序列中类间和类内的相似度信息,从而提升模型对特征的捕获能力。对于一个给定的时间序列,首先计算时间序列中每个时间步之间的相对位置差异,生成表示原始序列相对位置关系的矩阵。RPM 通过保留原始时间序列的冗余特征,使转换后的图像中类间和类内的相似度信息更为明显,从而有助于后续的特征提取和分类任务。

RPM 采用分段聚合近似方法生成一个新的平滑时间序列,并通过计算分段常数的平均值进行降维,保持原始时间序列的近似趋势并计算两个时间戳之间的相对位置,将预处理后的时间序列 X 转换为相对位置矩阵 M ,表达式为

$$M = \begin{bmatrix} \tilde{x}_1 - \tilde{x}_1 & \tilde{x}_2 - \tilde{x}_1 & \cdots & \tilde{x}_m - \tilde{x}_1 \\ \tilde{x}_1 - \tilde{x}_2 & \tilde{x}_2 - \tilde{x}_2 & \cdots & \tilde{x}_m - \tilde{x}_2 \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{x}_1 - \tilde{x}_m & \tilde{x}_2 - \tilde{x}_m & \cdots & \tilde{x}_m - \tilde{x}_m \end{bmatrix} \quad (1)$$

M 矩阵内的元素,例如 $\tilde{x}_1 - \tilde{x}_m$ 表示时间戳 \tilde{x}_1 和 \tilde{x}_m 之间的相对位置差。其每一行和每一列都以某一个时间戳 (x_1, x_2, \dots, x_m) 为参考,进一步表征整个序列的信息。

图 2 为 RPM 编码与原始数据(示例)对比图,原始数据垂直方向表示电功率值,水平方向表示采样点。编码后图中颜色的深度与原始数据的数值呈反比关系:颜色越深的区域表示原始时序数据越低,颜色越浅的区域表示原始时序数据的值越高;纯色区域表示原始数据的数值保持恒定或

仅有缓慢变化;高频率的颜色变化反映出数据呈现锯齿状波形,即数据的快速变动,低频颜色变化则代表数据的波动平滑。图中明显体现出数据的数值大小与其变化频率。




图2 RPM 编码与原始数据示例对比图

Fig.2 The comparison of RPM encoding and an example of original data

2 抽油机井故障诊断算法

2.1 分类基础模型

EfficientNet 的关键创新在于使用 MobileNetV2 的 MBConv 模块,结合深度可分离卷积减少了计算开销

本文基于 EfficientNet 模型,通过复合缩放方法同时优化网络的深度、宽度和输入分辨率,能在参数量显著减少的情况下实现卓越的分类精度。EfficientNet 通过复合缩放策略避免了传统网络设计中的单一缩放方法,确保网络在各个维度的协同增长。

2.2 改进 MBConv 模块

在深度学习中,注意力机制广泛应用于提升模型对关键信息的聚焦能力,在 MBConv 模块中的 SE 注意力机制进一步增强了模型的代表能力。本文改进 MBConv 模块,进一步将模块中的 SE 注意力替换为 CA 注意力^[16]。CA 注意力机制通过结合空间和通道信息,动态调整各特征的重要性,提升了网络的特征表达能力。改进后的 MBConv 模块结构如图 3 所示。




图3 改进 MBConv 模块结构图

Fig.3 Improved MBConv module structural diagram

2.3 Dropout 层

神经网络的过拟合问题一直是模型性能优化的主要障碍之一。为了有效防止过拟合现象,提高模型对故障特征的提取和分类能力,本文在改进后的 EfficientNet 网络中引入 Dropout 层^[17]。Dropout 层是一种为了减少神经网络过拟合的正则化技术,在网络训练过程中随机失活一定比例的神经元,可以确保网络在每次训练时都能处理不同的子网络。

引入 Dropout 层的数学描述如下。

$$r_j^l \sim \text{Bernoulli}(p) \quad (2)$$

$$\tilde{y}^l = r^l \cdot y^l \quad (3)$$

$$z_i^{l+1} = w_i^{l+1} \tilde{y}^l + b_i^{l+1} \quad (4)$$

$$y_i^{l+1} = f(z_i^{l+1}) \quad (5)$$

式中: r_j^l 表示在第 l 层中第 j 个神经元的保留、丢弃标志,其为随机变量;Bernoulli(p) 为伯努利分布, p 为保留概率; r^l 为由伯努利分布生成的随机向量,在第 l 层用于 Dropout 操作; y^l 为第 l 层的输出向量; \tilde{y}^l 表示应用 Dropout 操作后的第 l 层的神经元输出; z_i^{l+1} 为第 $l+1$ 层中第 i 个神经元的线性变换结果; w_i^{l+1} 表示第 i 个神经元在第 $l+1$ 层中的权重向量; b_i^{l+1} 表示第 $l+1$ 层中第 i 个神经元的偏置;函数 $f(\cdot)$ 为 ReLU 激活函数; y_i^{l+1} 是第 $l+1$ 层第 i 个神经元的输出。在引入 Dropout 层后,输出向量的计算可以视为经过一种基于伯努利分布的随机筛选过程,在每次前向传播时,网络中的一部分神经元会被随机丢弃。

2.4 整体网络结构

经过改进 MBConv 后的 EfficientNet 的整体网络结构如图 4 所示。首先,输入的 RPM 图像通过一个结合 CA 的卷积层进行初步特征提取;多层堆叠的改进 MBConv 模块进一步提取图像特征;输出的特征图通过额外的卷积层用于进一步处理特征图,整合提取的特征;经过展平层将多维的特征图转换为一维;通过全局平均池化操作生成特征向量,该特征向量经过 Dropout 层减少过拟合后通过全连接层进行调整,最终通过一个包含 3 个神经元的输出层实现 3 分类,分级评价不同程度的故障状态。

3 实验研究

3.1 数据集

本节实验平台使用 NVIDIA 3060 显卡,配备




图4 网络结构图

Fig. 4 Network architecture diagram

Intel i5-12500H CPU。网络模型利用 Python 搭建,采用 GPU 进行加速训练。收集了同种工况下不同程度油井电参数故障数据,将所有油井故障数据通过 RPM 方法编码得到像素为 $224 \times 224 \times 3$ 的图片集,构成每类故障各 300 个不同周期的样本。选取 270 个样本作训练集,剩余 30 个样本作测试集。抽油机部分参数如表 1 所示,试验抽油机如图 5 所示。

表 1 抽油机部分参数

Table 1 Partial oil well pump parameters

参数	1#	2#	3#	...
抽油机型号	CYJY14 - 5.5 - 89HB	CYJ10 - 3 - 53HB	CYJ10 - 4.2 - 53HB	...
游梁前臂/m	5.52	3.01	4.37	...
游梁后臂/m	3.14	2.40	2.69	...
抽油泵直径/mm	38.00	44.00	57.00	...
冲程/m	5.53	3.01	4.21	...
泵挂深度/m	2 000.00	1 696.00	1 699.20	...
油藏压力/MPa	20.00	20.00	20.00	...
历史产液量/ ($\text{m}^3 \cdot \text{d}^{-1}$)	19.88	10.00	10.00	...



图5 试验抽油机

Fig. 5 Experimental oil well pump

3.2 电参数数据与工况分析

在实际数据收集,工况数据通常会呈现出逐渐变化的趋势。本研究旨在比较不同故障程度下的典型数据,筛选出最适合用于模型训练的数据集,以确保所选数据集不仅具备代表性,还能够在模型训练中发挥最佳效果。

以曲柄转角作为横坐标,直观地观察循环过程中电功率的变化,不同故障状态的抽油机井电参数及 RPM 图如图 6、图 7 所示。

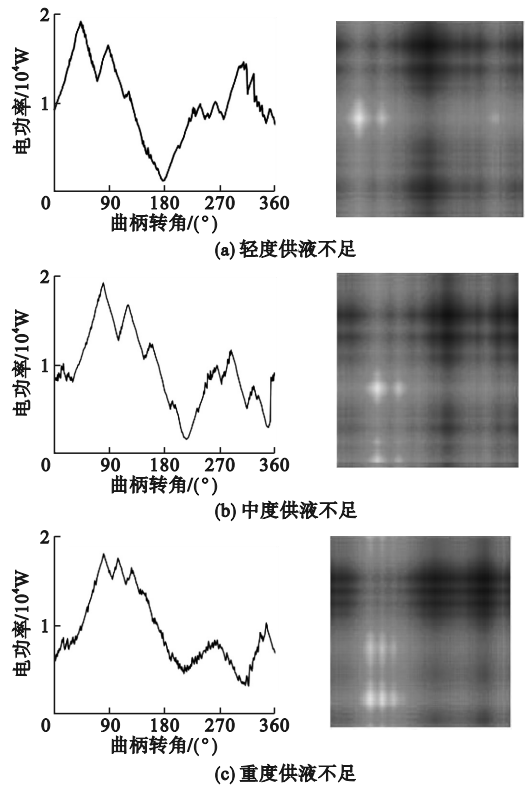


图6 不同程度供液不足电参数与 RPM 图

Fig. 6 The graphs of electrical parameters of insufficient liquid supply and RPM images

3.3 实验结果

为验证本研究提出方法的有效性,使用两种不同故障类型进行分类实验,并采用精确率、召回率和 F1 分数三种评价指标对所提出的方法进行评估。

表 2 为评价方法性能表,通过表内数据可以观察到游动阀漏失和供液不足的分级评价结果在各评估指标上的表现,验证了所提出方法的优越性和可靠性。

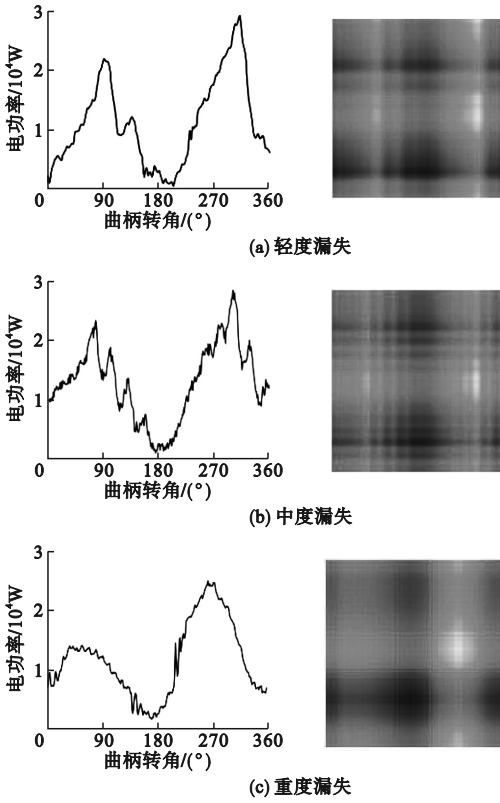


图 7 不同程度游动阀漏失电参数与 RPM 图
Fig. 7 The graphs of leakage parameters of traveling valve and RPM graphs

表 2 评价方法性能

Table 2 Comparison of evaluation metrics

故障	评价指标	轻度	中度	重度	均值
游动阀漏失	精确率	0.903 2	0.925 9	0.906 2	0.911 8
	召回率	0.933 3	0.833 3	0.966 7	0.911 1
	F1 分数	0.918 0	0.877 2	0.935 5	0.910 2
供液不足	精确率	0.903 2	0.931 0	0.966 7	0.933 6
	召回率	0.933 3	0.900 0	0.966 7	0.933 3
	F1 分数	0.918 0	0.915 3	0.966 7	0.933 3

为了更加直观地展示实验结果,本文采用混淆矩阵对测试结果进行表示。图 8 为供液不足和游动阀漏失的混淆矩阵,可以清晰地观察到模型在各类别上的预测情况和真实标签之间的对应关系。

为验证本研究提出模型的性能,采用相同数据集与多种深度学习模型进行性能比较,旨在评估各个模型在处理具体数据集时的效果,结果如表 3 所示,可以看出本文模型在测试集上的准确率、诊断所需时间均具有优势。

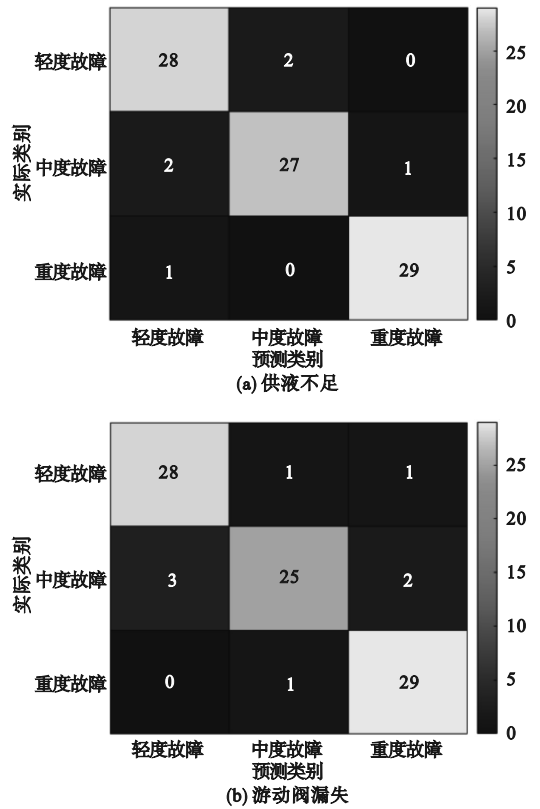


图 8 混淆矩阵图

Fig. 8 Confusion matrix diagram

表 3 模型性能对比表

Table 3 Comparison of model performance

模型名称	准确率/%	平均评价时间/s
本文模型	91.1	0.675
EfficientNet-B0 ^[18]	88.9	0.720
Shufflenet ^[19]	84.4	0.693
GoogLeNet ^[20]	78.8	0.890
Resnet-50 ^[21]	83.3	1.440

4 结论

为了提升抽油机井故障分级评价方法的准确性,鉴于深度学习方法在处理二维图像方面的优势,本文提出一种将 RPM 图像编码方法与改进 EfficientNet 模型相结合的故障评价方法。通过引入 CA 注意力机制改进 MBConv 模块,以更好地捕捉故障的空间特征和通道特征,增强故障不同状态特征中重要信息的权重。改进 MBConv 模块提高了 EfficientNet 模型特征提取能力,增强了模型的性能。通过实验得出供液不足和游动阀漏失故障分级评价的精确率分别为 93.36% 和 91.18%,验证了所提方法的可行性。该研究结果

为油井生产运维提供了更加可靠和智能化的故障分级评价手段。

参考文献 (References):

- [1] 黄迅迪, 庞雄文. 基于深度学习的智能设备故障诊断研究综述[J]. 计算机科学, 2023, 50(5): 93-102.
HUANG X D, PANG X W. Review of intelligent device fault diagnosis based on deep learning [J]. Computer Science, 2023, 50(5): 93-102. (in Chinese)
- [2] LV X X, FENG L, WANG H X, et al. Quantitative diagnosis method of the sucker rod pump system based on the fault mechanism and inversion algorithm [J]. Journal of Process Control, 2021, 104: 40-53.
- [3] 陆建明, 崔兵, 温后珍, 等. 抽油泵示功图故障诊断方法综述[J]. 内蒙古石油化工, 2024, 50(3): 35-40, 52.
LU J M, CUI B, WEN H Z, et al. The synthetic description in the failure diagnosis methods for pump dynamograph [J]. Inner Mongolia Petrochemical Industry, 2024, 50(3): 35-40, 52. (in Chinese)
- [4] YIN C Z, ZHANG K, ZHANG L M, et al. Imbalanced working states recognition of sucker rod well dynamometer cards based on data generation and diversity augmentation [J]. SPE Journal, 2023, 28(4): 1925-1944.
- [5] ZHENG B Y, GAO X W, LI X Y. Diagnosis of sucker rod pump based on generating dynamometer cards [J]. Journal of Process Control, 2019, 77: 76-88.
- [6] SREENIVASAN H, KRISHNA S. Automatic sucker rod pump fault diagnostics by transfer learning using GoogleNet integrated machine learning classifiers [J]. Process Safety and Environmental Protection, 2024, 191: 14-26.
- [7] LI K, HAN Y, WANG T. A novel prediction method for down-hole working conditions of the beam pumping unit based on 8-directions chain codes and online sequential extreme learning machine [J]. Journal of Petroleum Science and Engineering, 2018, 160: 285-301.
- [8] WEI J L, GAO X W. Fault diagnosis of sucker rod pump based on deep-broad learning using motor data [J]. IEEE Access, 2020, 8: 222562-222571.
- [9] ZHENG B Y, GAO X W, PAN R. Sucker rod pump working state diagnosis using motor data and hidden conditional random fields [J]. IEEE Transactions on Industrial Electronics, 2020, 67(9): 7919-7928.
- [10] ZHANG B, GAO X W, LI X Y. Complete simulation and fault diagnosis of sucker-rod pumping (includes associated comment) [J]. SPE Production & Operations, 2021, 36(2): 277-290.
- [11] 李翔宇, 袁春华, 高宪文. 有杆泵抽油井采油过程建模 [J]. 沈阳理工大学学报, 2021, 40(1): 12-18.
LI X Y, YUAN C H, GAO X W. Modelling of sucker-rod pumping process [J]. Journal of Shenyang Ligong University, 2021, 40(1): 12-18. (in Chinese)
- [12] 李翔宇, 郭亦晗, 袁春华. 基于改进变分模态分解的抽油井偏磨程度诊断 [J]. 沈阳理工大学学报, 2024, 43(1): 1-8.
LI X Y, WU Y H, YUAN C H. Diagnosis of the degree of wear of oil wells based on improved variational mode decomposition [J]. Journal of Shenyang Ligong University, 2024, 43(1): 1-8. (in Chinese)
- [13] HE Y F, GUO Z J, WANG X, et al. A hybrid approach of the deep learning method and rule-based method for fault diagnosis of sucker rod pumping wells [J]. Energies, 2023, 16(7): 3170.
- [14] WU Y, FENG Z M, LIANG J, et al. Fault diagnosis algorithm of beam pumping unit based on transfer learning and DenseNet model [J]. Applied Sciences, 2022, 12(21): 11091.
- [15] LI T Y, ZHANG Y Q, WANG T. SRPM - CNN: a combined model based on slide relative position matrix and CNN for time series classification [J]. Complex & Intelligent Systems, 2021, 7(3): 1619-1631.
- [16] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 13708-13717.
- [17] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [18] TAMA B A, VANIA M, KIM I, et al. An EfficientNet-based weighted ensemble model for industrial machine malfunction detection using acoustic signals [J]. IEEE Access, 2022, 10: 34625-34636.
- [19] WANG Y X, YAN J, SUN Q F, et al. ShuffleNet-based comprehensive diagnosis for insulation and mechanical faults of power equipment [J]. High Voltage, 2021, 6(5): 861-872.
- [20] WANG S Q, FENG Z G. Multi-sensor fusion rolling bearing intelligent fault diagnosis based on VMD and ultra-lightweight GoogleNet in industrial environments [J]. Digital Signal Processing, 2024, 145: 104306.
- [21] LI X X, LI D, REN W X, et al. Loosening identification of multi-bolt connections based on wavelet transform and ResNet-50 convolutional neural network [J]. Sensors, 2022, 22(18): 6825.

(责任编辑: 和晓军)