

胡康康, 崔桂艳. 基于轴箱振动混合域特征的钢轨表面状态识别[J]. 智能计算机与应用, 2024, 14(5): 130–135. DOI: 10.20169/j.issn.2095-2163.240517

基于轴箱振动混合域特征的钢轨表面状态识别

胡康康^{1,2}, 崔桂艳³

(1 上海理工大学 材料与化学学院, 上海 200093; 2 中国科学院 上海微系统与信息技术研究所, 上海 200050;

3 上海工程技术大学 城市轨道交通学院, 上海 201620)

摘要: 在复杂的现场环境中, 识别模型必须具有实时数据处理能力、对不同状态的准确识别能力和良好的抗噪声能力。针对上述问题, 提出一种基于混合域特征和 VMD-LSTM 的钢轨表面状态识别方法, 用于识别钢轨表面的 5 种状态, 即: 道岔、接缝、损伤、道岔和损伤的混合状态以及正常状态。该方法主要包括 3 个阶段, 即: 混合域特征提取、特征选择和状态识别。通过仍处使用期的列车现场试验采集的振动加速度数据进行验证, 测试准确率达到 98.26%。实验结果表明, 该方法能准确识别钢轨表面状态, 可用于实际现场。

关键词: 轴箱振动信号; 钢轨表面状态识别; VMD; CDET; LSTM

中图分类号: U273.3

文献标志码: A

文章编号: 2095-2163(2024)05-0130-06

Recognition of rail surface state based on mixed domain features of axle box vibration

HU Kangkang^{1,2}, CUI Guiyan³

(1 School of Materials and Chemistry, University of Shanghai for Science and Technology, Shanghai 200093, China;

2 Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 200050, China;

3 School of Urban Rail Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: For complex on-site environments, recognition models must have real-time data processing capabilities, accurate recognition of different states, and good noise resistance. To address the aboved issues, a rail surface state recognition method based on mixed domain features and VMD-LSTM is proposed to identify five states of the rail surface, which are the mixed state of turnout, joint, damage, turnout and damage and normal state. This method mainly includes three stages, namely mixed domain feature extraction, feature selection and state recognition. The vibration acceleration data collected through on-site testing of in-service trains is verified, and the testing accuracy reaches 98.26%. The experimental results show that this method can accurately identify the surface state of steel rails and can be used in practical fields.

Key words: axle box vibration signal; identification of surface state of steel rails; VMD; CDET; LSTM

0 引言

随着铁路速度的提高, 高速铁路的安全性已成为研究的热点, 对钢轨缺陷的精准识别是确保列车运行安全的关键问题^[1]。现场采集的轴箱振动信号通常为混叠信号并且包含大量噪声, 需要采取有效的处理^[2]。Dragomiretskiy 等学者^[3]提出一种非平稳信号处理方法: 变分模态分解(VMD), 对采样和噪声具有较好的鲁棒性, 可以降低复杂度高和非

线性强的时间序列非平稳性, 分解获得包含多个不同频率尺度且相对平稳的子序列, 广泛应用于故障诊断和识别^[4]。

针对服役钢轨故障数据获取困难及小样本问题, 通过构建混合域特征集, 提取时域特征、频域特征和时频域特征多方面反映钢轨表面状态信息。但高维特征集中会存在冗余特征, 影响模型的识别结果和计算效率。所以, 需要对高维特征集进行降维^[5]。主要有主成分分析(PCA)^[6]、核主成分分析

基金项目: 中国科学院关键技术人才项目(E07YRA1)。

作者简介: 胡康康(1997-), 男, 硕士研究生, 主要研究方向: 聚焦离子束技术开发相关工作; 崔桂艳(1994-), 女, 硕士研究生, 主要研究方向: 载运工具故障诊断与控制。

收稿日期: 2023-04-13

(KPCA)^[7]、距离评估技术^[8]等。文献[9]提出一种基于补偿距离评估技术的特征选择方法。

随着人工智能技术的不断发展,深度学习体系结构即递归神经网络(RNN)^[10]、卷积神经网络(CNN)^[11]、长短期记忆(LSTM)^[12]等在状态识别领域中得到广泛的应用。针对单传感器反映的信息不全面问题,利用多传感器信息融合为故障诊断提供更多的信息。

1 变分模态分解参数优化

1.1 VMD 理论

VMD 是一个完全非递归的变分模态分解模型。在该算法中,本征模态函数(IMF)被定义为一个有带宽限制的调幅-调频函数,VMD 算法是通过构造并求解约束变分问题,将原始信号分解为指定个数的 IMF 分量。在对信号进行 VMD 分解之前,需要确定 VMD 的参数,确定影响参数后,对信号进行 VMD 算法处理,得到一系列本征模函数^[12]。

1.2 VMD 模数确定

采用一种由希尔伯特变换计算峰度值的方法,从而有效地优化 VMD 模数,本文采用惩罚因子和带宽的默认值 $\alpha = 2000, s = 0$, 初始模数设为 $K = 2$, 借鉴唐贵基等学者^[13]对模数 K 的讨论范围。选择 $K \in [2, 15]$ 作为模数的搜索域,步长设置为 1。

假设 VMD 的模数为 $K, K \in [2, 15]$, 可以计算出每个模的包络,即:

$$xt_k^i = \left| \frac{1}{\pi t} \cdot x_k^i(t) \right|, i = 1, 2, \dots, K \quad (1)$$

其中, i 表示 K 的第 i 种模式; xt_k^i 表示绝对值 (K 的第 i 种模式的 HT 的结果); $x_k^i(t)$ 表示当模式为 K 时, VMD 产生的第 i 个模式。

此外, K 的第 i 个模式的包络峰度计算公式具体如下:

$$ek(i) = \frac{E(xt_k^i - \mu(xt_k^i))^4}{\sigma(xt_k^i)^4}, i = 1, 2, \dots, K \quad (2)$$

其中, $\mu(xt_k^i)$ 表示 xt_k^i 的均值; $\sigma(xt_k^i)$ 表示 xt_k^i

的标准偏差;式(2)中的分子表示 xt_k^i 的四阶中心矩。

由此就可以获得局部最大 ek_k^{\max} :

$$ek_k^{\max} = \max(ek_1, ek_2, ek_3, \dots, ek_k) \quad (3)$$

因为 K 的搜索范围为 $[2, 15]$, 搜索步长设置为 1, 所以在整个搜索范围内可以获得 14 个局部最大值。因此,可以得到全局最大值:

$$ek_g^{\max} = \max(ek_2^{\max}, ek_3^{\max}, ek_4^{\max}, \dots, ek_{15}^{\max}) \quad (4)$$

根据式(4)可以得到取 ek_g^{\max} 时,对应的 K 值,用 K' 表示,这里的 K' 可以由式(5)计算得到:

$$K' = \operatorname{argmax}(ek_g^{\max}) \quad (5)$$

1.3 IMF 分量选择

VMD 方法获得的各 IMF 分量包括了原始信号不同时间尺度的局部特征,前几个 IMF 分量体现了原始信号的主要特征。为有效保留原始信号的故障特征,同时避免噪声等成分的干扰,采用相关系数法筛选分解后的各个 IMF 分量,使用相关系数最大的 IMF 分量计算混合域特征。相关系数的计算公式见如下^[14]:

$$\rho(i) = \frac{\sum_{j=1}^L x(j) IMF_i(j)}{\sqrt{\sum_{j=1}^L x^2(j) \sum_{j=1}^L IMF_i^2(j)}} \quad (6)$$

其中, L 表示信号长度, $\rho(i)$ 表示第 i 个 IMF 分量与原始信号 $x(t)$ 之间的相关系数。

2 基于混合域特征的钢轨表面状态识别建模

2.1 钢轨表面状态振动特征

通过提取原始振动信号的时域和频域特征,结合所选 IMF 的时域和频域特征以及能量和熵特征构建混合域特征集,能够表征信号的频率分布特征和变化趋势以及在不同时刻和频率处的能量信息等,全面挖掘轨面状态特征信息。

本节采用统计分析方法归纳总结 15 种时域特征参数;基于 FFT 得到的频域信号提取 10 种频域特征参数;基于优化 VMD 筛选的 IMF 分量提取能量、排列熵、样本熵和模糊熵四种时频特征参数,见表 1。

表 1 特征参数表

Table 1 Characteristic parameters table

时域特征			频域特征			时频域特征		
最大值	标准差	方根幅值	频谱幅值样本均值	表征主频带位置	频率偏度	能量	排列熵	样本熵
最小值	方差	波形因子	平均频率	频率能量集中度	频率峭度	模糊熵		
平均值	RMS	峭度因子	频率均方根值	频谱能量集中度	频率方差			
峰-峰值	峰度	脉冲因子	标准化频谱均值					
绝对均值	峰值	裕度因子						

2.2 钢轨表面状态特征选择与降维

补偿距离评估技术 (CDET) 是利用距离评估指标进行敏感特征选择的方法, 充分考虑特征对状态识别的敏感性, 降低特征集维度, 本文将就其算法原理展开如下^[9]。

设含有 C 个模式类 $\omega_1, \omega_2, \dots, \omega_C$ 的特征集为 $\{p_{c,m,k}\}, c = 1, 2, \dots, C, m = 1, 2, \dots, M_c, k = 1, 2, \dots, K$ 。其中, $p_{c,m,k}$ 为状态 c 下第 m 个样本的第 k 个特征, M_c 为状态 c 下样本总数, K 为每个样本特征数目。因此总共可得 $\sum_{c=1}^C M_c$ 个样本集, 共计 $K \sum_{c=1}^C M_c$ 个特征。对于原理步骤, 研究给出阐释分述如下。

(1) 计算 $\omega_c (c = 1, 2, \dots, C)$ 类特征向量的平均距离, 运算公式可写为:

$$d_{c,k} = \frac{1}{M_c(M_c - 1)} \sum_{i=1}^{M_c} \sum_{j=1}^{M_c} |p_{c,i,k} - p_{c,j,k}| \quad (7)$$

对 $d_{c,k} (c = 1, 2, \dots, C)$ 求平均类内距离, 运算公式可写为:

$$d_k^\omega = \frac{1}{C} \sum_{c=1}^C d_{c,k} \quad (8)$$

(2) 定义并计算 d_k^ω 的方差因子, 运算公式可写为:

$$v_k^\omega = \frac{\max(d_{c,k})}{\min(d_{c,k})} \quad (9)$$

(3) 计算 C 个模式类的类间距离, 运算公式可写为:

$$d_k^b = \frac{1}{C(C - 1)} \sum_{c=1}^C \sum_{e=1}^C |\mu_{c,k} - \mu_{e,k}| \quad (10)$$

其中, $\mu_{c,k} = \frac{1}{M_c} \sum_{m=1}^{M_c} p_{c,m,k}$ 为 ω_c 类中所有第 k 个特征均值。

(4) 定义并计算 d_k^b 的方差因子, 运算公式可写为:

$$v_k^b = \frac{\max(\mu_{e,k} - \mu_{c,k})}{\min(\mu_{e,k} - \mu_{c,k})} \quad (11)$$

(5) 定义并计算补偿因子, 运算公式可写为:

$$\gamma_k = \frac{1}{v_k^\omega / \max(v_k^\omega) + v_k^b / \max(v_k^b)} \quad (12)$$

(6) 计算距离评估指标 α_k , 运算公式可写为:

$$\alpha_k = \gamma_k \frac{d_k^b}{d_k^\omega} \quad (13)$$

对 α_k 进行归一化处理, 得到归一化的距离评估指标为 $\bar{\alpha}_k$, 运算公式可写为:

$$\bar{\alpha}_k = \frac{\alpha_k}{\max(\alpha_k)} \quad (14)$$

设定阈值 $\varphi (\varphi \in [0, 1])$ 大小, 从特征集 $\{p_{c,m,k}\}$ 中选择 $\bar{\alpha}_k \geq 0.5$ 的特征, 构造降维后的输入特征集。

2.3 多通道振动传感器信息融合

四通道振动信号中期融合的主要步骤如下:

(1) 分别对 4 个通道传感器测得的原始振动信号 x_1, x_2, x_3 和 x_4 进行优化变分模态分解 (VMD);

(2) 利用相关系数法筛选原始振动信号和本征模态分量 (IMFs) 相关系数最大的 IMF 分量;

(3) 计算原始振动信号的 15 维时域特征和 10 维频域特征以及计算筛选 IMF 分量的 15 维时域特征、10 维频域特征和 4 维时频域特征;

(4) 分别构造 4 个通道的混合域特征集以及对 4 个通道混合域特征集进行依次排列拼接, 构造多通道融合的混合域特征集。

2.4 钢轨表面状态识别模型构建

利用长短时记忆网络 (LSTM) 建立轨面状态识别模型。叠加多个 LSTM 层, 利用输入和输出之间的非线性映射层进行分层特征学习, LSTM 的内部结构如图 1 所示, 整体网络结构如图 2 所示^[15]。




图 1 LSTM 网络内部结构图

Fig. 1 Internal structure of LSTM network

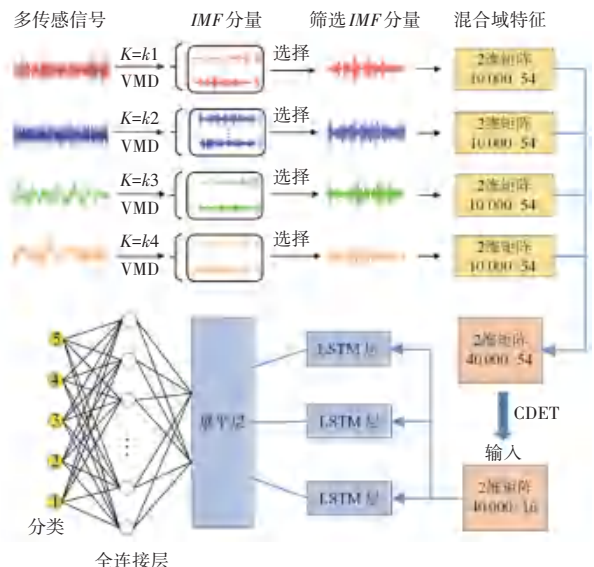


图 2 LSTM 网络结构图

Fig. 2 LSTM network structure diagram

3 基于现场试验数据的模型验证及结果分析

3.1 数据集构造

测试设备采用4个振动加速度传感器和1个高速线阵相机。数据采集系统,包括数据采集单元、数据传输和数据储存设备(接收终端)。振动信号的采集方案如图3所示。

利用线阵相机拍摄钢轨图像,通过图像识别软件提取4种特殊状态钢轨图像并获得图像对应的采集时间,提取4个通道CH1、CH2、CH3和CH4轴箱振动加速度数据。制作4个通道5种轨面状态样本数据集,即道岔、接缝、损伤、道岔+损伤、正常这5种状态样本数据集。

3.2 VMD 模数分析

在搜索域中,4个通道模式数 K 和包络峰度最

大值之间的关系绘制在图4中。针对钢轨表面5种状态样本,可以得到4个通道每个样本取最佳模式数 K' 时包络峰度的最大值。




图3 轴箱振动传感器安装方案

Fig. 3 Axle box vibration sensor installation solution

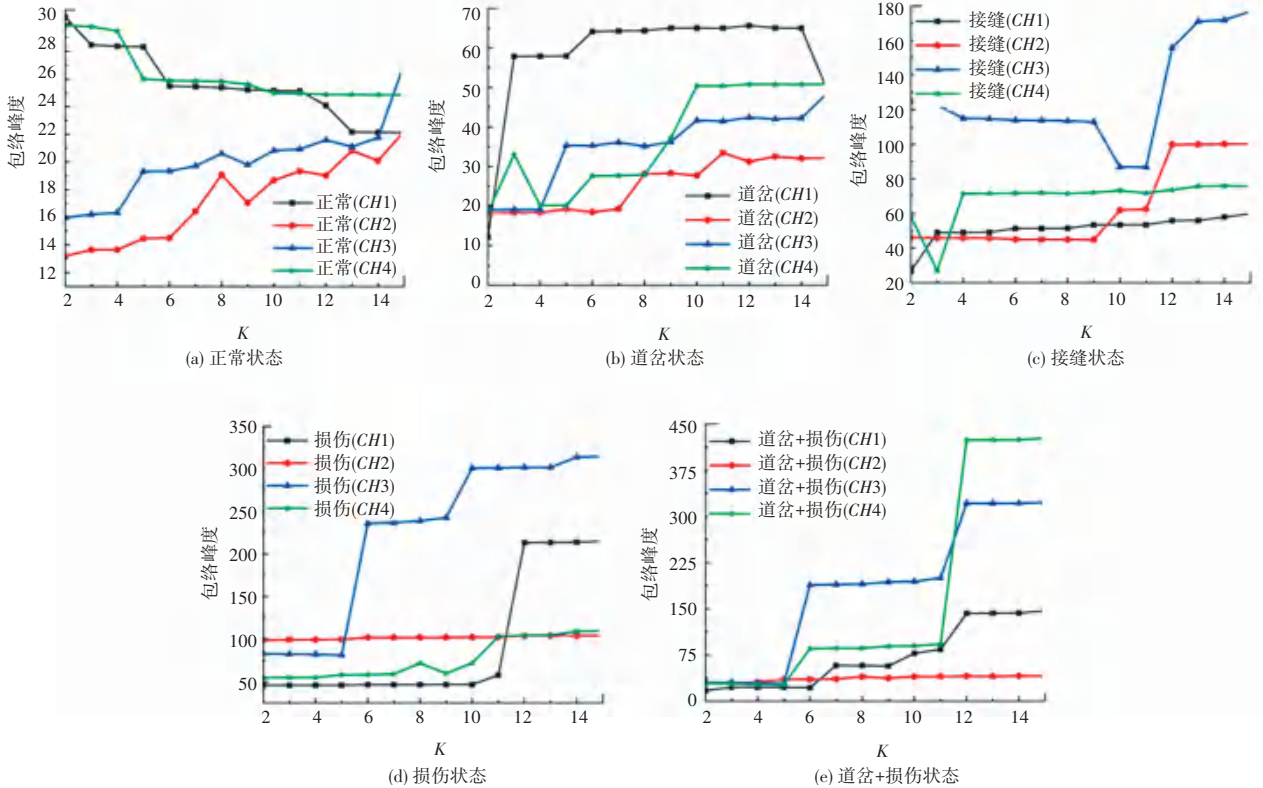


图4 K与局部最大包络峰度

Fig. 4 K and local maximum envelope kurtosis

3.3 状态识别方法实现

基于轴箱振动混合域特征的钢轨表面状态识别方法主要包括4个部分内容。其中,第一部分:轮轨智能监测系统;第二部分:混合域特征提取;第三部分:输入特征降维优化;第四部分:建立轨面状态识别模型,图5是整体算法流程。

3.4 状态识别结果与分析

根据3.1节构建的钢轨振动信号数据集验证基

于轴箱振动混合域特征的钢轨表面状态识别方法的效果。钢轨表面5种状态一共生成40 000个样本,每种状态8 000个样本。将网络运行5次,5次测试得到的测试集识别准确率和损失率见表2。其中,第4次测试的训练集和测试集精度变化曲线如图6所示,第4次测试的训练集和测试集损失变化曲线如图7所示。

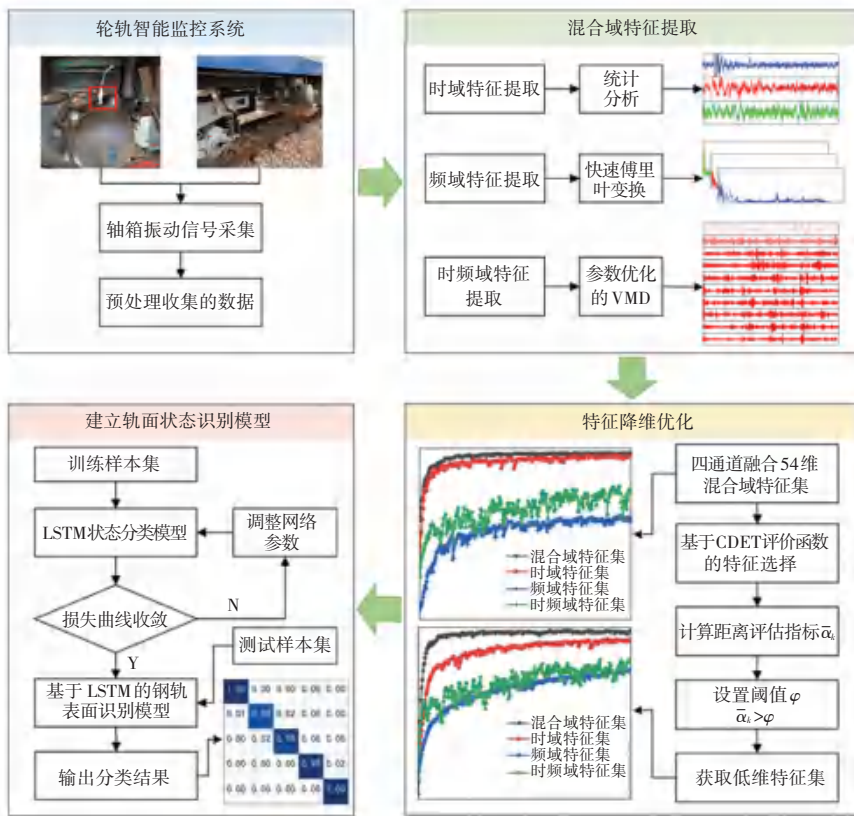


图5 整体算法流程图

Fig. 5 Overall algorithm flow chart

表2 多次测试的准确率和损失

Table 2 Accuracy and loss rates for multiple tests %

序号	精度	损失
1	97.9	0.072 9
2	98.4	0.064 2
3	98.4	0.066 1
4	98.5	0.051 4
5	98.1	0.070 1

分析表2中的数据,本文提出的方法获得了较好的结果,5次测试的测试集平均识别准确率为98.26%。由此可见,利用基于轴箱振动混合域特征的多通道融合钢轨表面状态识别方法能够有效实现轨面状态识别且稳定性较高。




图6 训练集和测试集的精度变化

Fig. 6 Accuracy changes of training set and test set




图7 训练集和测试集的损失变化

Fig. 7 Loss changes of training set and test set

从图6和图7可以看出,无论训练、还是测试,精度曲线迅速上升并趋于稳定,损失曲线迅速下降并趋于稳定,经过300次迭代后,最终的测试精度和损失的值分别为98.50%和5.14%。

3.5 模型性能对比

为了验证基于轴箱振动混合域特征的钢轨表面状态识别方法的有效性,并与其他4种方法进行对比实验。表3展示了本文所提方法与其他4种方法的对比结果,可以看出,基于轴箱振动混合域特征的钢轨表面状态识别方法相较于其他4种对比方法识别准确率高,稳定性好。

表3 不同状态识别方法的比较

Table 3 Comparison of different state recognition methods

方法	钢轨表面状态识别方法	准确率/%
方法1	VMD+混合域+LSTM(融合)	98.03
方法2	VMD+混合域+CDET+LSTM(CH1)	93.62
	VMD+混合域+CDET+LSTM(CH2)	95.48
	VMD+混合域+CDET+LSTM(CH3)	96.73
	VMD+混合域+CDET+LSTM(CH4)	96.08
	VMD+时域+CDET+LSTM(融合)	92.91
方法3	VMD+频域+CDET+LSTM(融合)	79.47
	VMD+时频域+CDET+LSTM(融合)	77.87
本文方法	VMD+混合域+CDET+LSTM(融合)	98.26

4 结束语

本文提出一种基于轴箱振动混合域特征的钢轨表面状态识别方法并对其开展相关研究。针对现场试验数据包含大量背景噪声问题以及服役钢轨故障状态小样本问题,从全面挖掘钢轨表面状态特征以及提高识别模型准确率的角度出发进行相关研究。研究得到如下结论:

(1)提出了一种基于希尔伯特变换计算包络峰度最大值的VMD优化方法处理振动信号,利用相关系数法筛选IMF,能够有效降低噪声干扰;

(2)通过提取原始振动信号的时域和频域特征,结合所选IMF的时域和频域特征以及能量和熵特征构建混合域特征集;并利用补偿距离评估技术(CDET)对高维特征集进行降维,选择距离评估指标 $\bar{\alpha}_k \geq 0.5$ 的特征作为敏感特征,构建低维特征集;

(3)基于现场试验数据,测试准确率达到98.26%。相比于单一通道模型,多通道融合模型的识别精度分别提升了4.64%、2.78%、1.53%和2.18%,解决了单一通道信息不全面等问题,提升了钢轨表面状态识别精度。

参考文献

- [1] 王兵水,郑树彬,李立明,等.基于YOLO改进算法的轨道扣件状态检测研究[J].智能计算机与应用,2020,10(1):137-143.
- [2] 段智博,肖曼琳,金捷.基于STM32车载查询器故障诊断系统设计[J].智能计算机与应用,2022,12(7):195-201.
- [3] DRAGOMIRETSKIY K, DOMINIQUE Z. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [4] LI Hua, LIU Tao, WU Xing, et al. An optimized VMD method and its applications in bearing fault diagnosis[J]. Measurement, 2020, 166: 108185.
- [5] WANG Tianyang, HAN Qinkai, CHU Fulei, et al. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review[J]. Mechanical Systems and Signal Processing, 2019, 126(1): 662-685.
- [6] 白雲杰,贾希胜,梁庆海,等.基于PCA-EDT-CNN的柴油发动机故障诊断方法[J].机械强度,2022,44(6):1271-1278.
- [7] 张天瑞,李金洋.基于自适应VMD-KPCA特征提取与SSA-SVM方法的滚动轴承故障诊断[J].机械设计,2022,39(7):63-73.
- [8] YANG B S, HAN T, AN J L. ART-KOHONEN neural network for fault diagnosis of rotating machinery[J]. Mechanical Systems and Signal Processing, 2004, 18(3): 645-657.
- [9] SE Haifeng, ZHOU Lei, XU Shiming, et al. Selecting sensitive features using CDET for bearing fault diagnosis[J]. Journal of Physics: Conference Series, 2022, 2218(1): 012063.
- [10] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [11] YE H C W, CHEN Rongshun. Using convolutional neural network for vibration fault diagnosis monitoring in machinery[C]//2018 IEEE International Conference on Advanced Manufacturing (ICAM). Yunlin: IEEE, 2018: 246-249.
- [12] YU Yong, SI Xiaosheng, HU Changhua, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1235-1270.
- [13] 唐贵基,王晓龙.变分模态分解方法及其在滚动轴承早期故障诊断中的应用[J].振动工程学报,2016,29(4):638-648.
- [14] 刘东瀛,邓艾东,刘振元,等.基于EMD与相关系数原理的故障声发射信号降噪研究[J].振动与冲击,2017,36(19):71-77.
- [15] 马丽莹,魏云冰.一种变分模态分解与Adam优化的LSTM电价预测方法[J].智能计算机与应用,2022,12(12):142-146,152.