

汽车测功机类设备预测性维护系统设计

刘春来 杨春辉 刘洪伟 林长宏 崔明雨 王洪超 刘猛

(中国第一汽车股份有限公司研发总院, 长春 130013)

【欢迎引用】刘春来, 杨春辉, 刘洪伟, 等. 汽车测功机类设备预测性维护系统设计[J]. 汽车文摘, 2025(6): 57-62.

【Cite this paper】LIU C L, YANG C H, LIU H W, et al. Design of Predictive Maintenance System for Automotive Dynamometer Equipment[J]. Automotive Digest (Chinese), 2025(6): 57-62.

【摘要】新能源电动车产业面临全面升级, 竞争快速加剧, 产品开发周期不断缩短, 对研发设备的测试效率和测试成本提出了更严峻的考验。为了进一步提升装备研发效能, 快速满足新能源高端产品开发需求, 深入研究并设计了一种研发设备预测性维护系统, 通过物联网、小波变换、深度学习、多元高斯分布、长短时记忆神经网络等关键技术, 开发故障诊断、寿命预测算法模型, 实现设备关键故障以及剩余寿命的预测。结果表明, 本系统可大幅度减少停机和维修时长, 实现研发、维修资源更高效的利用。

关键词: 预测性维护; 数据采集; 网络架构; 故障诊断; 剩余寿命预测

中图分类号: U468 文献标志码: A DOI: 10.19822/j.cnki.1671-6329.20240197

Design of Predictive Maintenance System for Automotive Dynamometer Equipment

Liu Chunlai, Yang Chunhui, Liu Hongwei, Lin Changhong, Cui Mingyu, Wang Hongchao, Liu Meng
(Global R&D Center, China FAW Corporation Limited, Changchun 130013)

【Abstract】The newenergy vehicle industry is faced with comprehensive upgrading and rapid competition, but the product development cycle is continuously shortened, and synchronization brings more severe test on efficiency and cost of R&D equipment. In order to further improve the equipment R&D efficiency and quickly meet the new energy high-end product development needs. A kind of predictive maintenance system for R&D equipment is researched and designed in depth. Fault diagnosis and life prediction algorithm model are developed through key technologies such as Internet of Things, wavelet transform, deep learning, multiple Gaussian distribution and long and short time memory neural network, so as to realize the prediction of key faults and remaining life of equipment. The results show that the system can significantly reduce the downtime and maintenance time, and achieve more efficient use of R&D and maintenance resources.

Key words: Predictive maintenance, Data acquisition, Network architecture, Fault diagnosis, Residual life prediction

0 引言

近年来, 汽车产品研发周期日益加快, 而提升测试设备可动率是确保产品研发效率的关键因素。设备的预测性维护技术对设备数字化赋能提效具有重要意义, 其可以提前预测设备故障及寿命, 避免设备长时间停机, 延长设备使用寿命, 进而降低研发成本。

在预测性维护领域, 已有学者通过先进的数据分析和机器学习技术, 对设备健康状态评估和故障预测

进行了深入探索。近年已在设备状态监测、故障诊断和预测性维护模型构建方面取得丰硕成果。张国萍^[1]通过全面收集和分析设备状态数据, 利用深度学习等先进技术, 实现对设备健康状态的精确评估以及对故障演化过程的预警预测。程伦新等^[2]通过对振动和电气数据的监测, 建立故障诊断、预测及运行优化等各类模型, 解决电机设备零部件损耗不确定的问题。李敏等^[3]提出基于优化并行二维卷积神经网络的滚动轴承智能故障诊断方法。刘益豪等^[4]通过卷积神经网络提取数据的多维特征, 同时采用双向长短时记忆网络有

效捕获其时间序列特征。黄庆归^[5]采用小波包变换与长短期记忆递归神经网络相结合的方式预测性维护,实现了对工业机器人伺服电机故障的实时监测。陈劲^[6]通过深度学习算法分析采集的海量数据,构建了高精度的生产质量预测模型。孙若依等^[7]构建了由物理设备层、物联网数据采集层、数字孪生数据层、虚拟设备层以及预测性维护服务层组成的多层次预测性维护框架。

本文基于现有研究成果,设计了一种完整的预测性维护方案,涉及采集架构搭建、网络架构搭建以及采集数据处理等关键环节,同时详细阐述了故障诊断和寿命预测模型的实现方法。此方案适用多种高速旋转类、周期运动性设备,本文以最常见的整车底盘测功机为例进行详细阐述。实践验证,本研究提出的方案具有较高预测准确率,可以显著提升设备运行效率,同时有效降低研发成本。

1 采集架构设计

1.1 底盘测功机结构

图1为汽车底盘测功机试验设备的典型结构,主要包括测功电机、传动轴、电机座、轴承座、力传感器、转速编码器以及负载端7个部分,其结构符合典型汽车旋转类试验设备的结构特征^[8]。




图1 底盘测功机结构示意图

1.2 传感器布置方案

本方案需布置的传感器主要包括末端三向振动传感器、电机温度传感器、顶端三向振动传感器、顶端温度传感器、轴座三向振动传感器、轴座温度传感器以及末端温度传感器等。传感器布置如图2所示。




图2 传感器布置方案

为保证采集方案的通用性并避免干扰原控制系统,采取非侵入式传感器点位布置方案。末端三向振动传感器和顶端三向传感器分别布置于电机外壳尾端和顶端,紧邻轴承两端,主要负责采集电机尾端和顶端轴承在 x 、 y 、 z 方向的振动数据,而轴座三向振动传感器布置于轴承座近轴承位置,主要负责采集轴承座内轴承和传动轴在 x 、 y 、 z 方向的振动数据。顶端温度传感器和末端温度传感器分别布置于电机外壳顶端和末端,紧邻轴承两侧,主要负责采集电机顶端和末端轴承实时温度。轴座温度传感器布置于轴承座近轴承位置,主要负责采集轴承座内轴承的实时温度。电机温度传感器布置于电机外壳中间,主要负责采集电机实时温度。

设备的对称和相似部位可按本布置方法进行类比拓展,转速、电流和电压等重要参数可通过设备自身控制器或外置传感器同步采集。

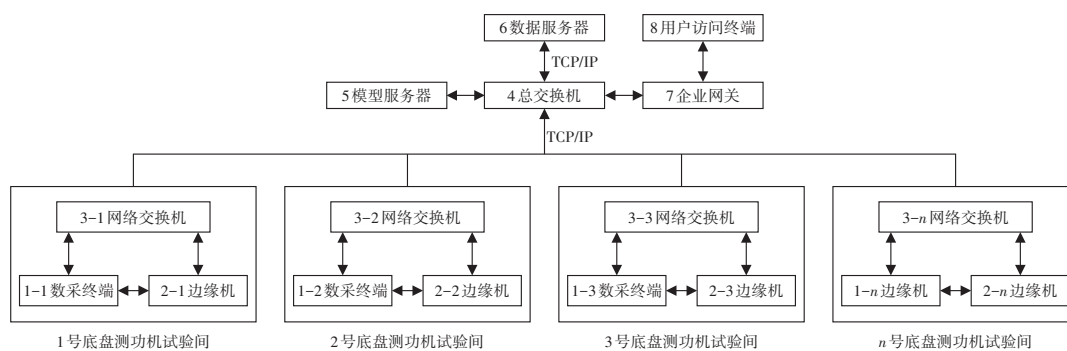
2 网络架构设计

2.1 数据传输架构

大多数底盘测功机需配合环境仓使用,且测功机本身存在电磁干扰,无线传输可靠性较低,因此采用屏蔽线束连接方式完成信号传输。如图3所示,本方案所需的网络设施主要包括数采终端、边缘机、网络交换机、总交换机、数据服务器、诊断服务器、企业网关以及用户访问终端8个部分。数采终端是所有传感器信号的采集、转换、滤波工具,最终实现数字信号的传输。边缘机负责运行诊断模型,通过接收数采终端实时传输的数据信号进行运行状态判定和故障诊断。网络交换机为各试验间内数据的交换中心,可实现信息的分配和集传。总交换机是试验间与外部的信息交互中心,可实现仓内和仓外信息交互。数据服务器为数据存储中心,负责持续接收和存储来自数采终端的传感器数据,是诊断和预测模型训练的数据库。模型服务器为模型训练和优化中心,可通过数据库内数据不断优化模型,提升预测准确率。企业网关为设备网与企业办公网数据交互中心,通过网段规划,保证数据透传和网络安全。用户访问终端包括个人电脑、手机等设施,用户可通过有线或无线方式访问设备状态、报警信息以及设备剩余寿命等数据。

2.2 数据传输过程

数据传输主要包括采集存储、模型训练、模型部署和预测诊断4个过程。在采集存储过程中,传感器数据、设备关键数据通过数采终端进行采集、转换和



注:传输控制协议/网际协议(Transmission Control Protocol/Internet Protocol, TCP/IP)。

图3 网络传输架构

汇总,并通过网络交换机、总交换机传输至数据服务器进行存储。在模型训练过程中,模型服务器周期性调用数据服务器内的历史数据,在原始模型基础上进行再次优化迭代,不断提升模型精确度。在模型部署过程中,将训练完成的模型通过总交换机、网络交换机部署到边缘机。在预测诊断过程中,边缘机负责执行测量模型算法,并结合数采终端传输的实时数据,进行故障诊断及寿命预测,并将结果通过网络交换机、总交换机、企业网关等网络设施将结果发送至用户访问终端。

对于设备台数较少或者预测实时性要求不高的用户,可将边缘机和模型服务器融合,进而有效降低部署成本。若在预测到具体故障后需触发急停或顺序下电等紧急逻辑,建议采用边缘机以提高系统实时性,确保试验稳定性及人员安全。

3 预测模型设计

3.1 诊断模型设计

诊断模型设计过程中,需基于数据服务器内的关键状态数据构建数据集,通过小波变化将采集的多维时域参数转换为多通道图像,进而通过图像处理技术以及深度学习技术实现设备故障自动检测与故障类型识别。通过建立深层模型,无需再对试验数据进行过多的信号特征提取,可以自适应地提取数据中的深层故障特征,实现智能自动化健康状况诊断^[9]。诊断模型的设计过程可以分为以下4个步骤。

(1)数据采集。选取工况正常的设备和已知故障类型的设备,分别进行数据采集,采样频率设置为 f 。

(2)基于小波变换的时序信号到图像的转换。 $X = \{x^1, x^2, \dots, x^N\}$ 为步骤(1)采集的数据,其中, x^i 为一段时序数据,表示在 T 时间内采集的第 i 种类型的运行参数, $x^i = \{x_1^i, x_2^i, \dots, x_T^i\}$, x_t^i 表示 i 类型运行参数在 t 时刻的数值。将每个类型的参数进行小波变换可

得:

$$WT^i(a, \tau) = \sqrt{a} \int_0^T f(t) * \psi(a*(t - \tau)) dt \quad (1)$$

式中:参数的时间跨度为由0到 T , a 为频率, τ 为时刻, $f(t)$ 为 t 时刻所采集的参数数值, $\psi(a*(t - \tau))$ 为小波在平移 τ 个单位并缩放 a 倍后的函数值, $WT^i(a, \tau)$ 为第 i 种类型的运行参数在时刻 τ 、频率为 a 时所转换成图像的像素值。确定 a 的取值范围为 $[0, A]$, τ 的取值范围为 $[0, T]$,最终得到 a 行 T 列的图像^[10]:

$$I^i = \begin{bmatrix} WT^i(A, 0) & \dots & WT^i(A, T) \\ \vdots & \ddots & \vdots \\ WT^i(0, 0) & \dots & WT^i(0, T) \end{bmatrix} \quad (2)$$

$$I = [I^0, I^1, \dots, I^N] \quad (3)$$

式中: I^i 为第 i 种类型的运行参数转换后得到的图像,最终将所有类型参数得到的图像合并成 a 行 T 列 n 通道的图像。

(3)基于深度卷积神经网络的多通道图像特征提取。通过步骤(2)将电机运行期间采集的多维度原始电信号 X 转换成了多通道图像 I ,通过卷积神经网络,从多通道图像 I 中提取特征。首先设置参数如下: H 为图片高度, W 为图片宽度, N 为图片通道数,卷积核数量与通道数相同, L 为卷积层数量, F 为卷积核大小, K 为特征深度。

在卷积过程中,卷积核中心位置遍历图像中的每个像素点,对应元素相乘后求和作为新提取特征的数值,遍历所有像素点后得到与输入图像相同大小的特征矩阵。之后经过最大池化操作(即相邻4个方形区域对应元素合并,以其中最大元素为新的特征值)将输入图像缩减为原来的一半。 K 同样为 L 维的向量,表示每层卷积得到新特征的深度。以最后一个卷积层的输出结果为步骤3的输出,结果记为 O ,是 $H' \times W' \times K^N$ 的矩阵,其中 H' 、 W' 和 K^N 分别为卷积层最后一层输出的高度、宽度和深度^[11]。

(4)全连接神经网络与故障判定。将步骤(3)得到的结果 O 中的所有元素拆分合并为一维向量,以此作为全连接神经网络的输入。该网络包含多个隐藏层,以其最后一层的输出结果 O' 是一个长度为 M 的向量, M 为设备状态的数量。关于设备状态的描述中,1 表示正常,2 至 M 表示对应的故障类型。最终通过 Softmax 函数,将 O' 进行归一化处理,以 O' 中最大的元素所在位置作为设备状态的最终预测值^[12]。故障状态主要包括电机故障、电机前后端轴承故障、传动轴不对中、传动轴松动以及负载不平衡。故障类型可以根据训练集中的故障样本种类具体定义。同时可根据故障类别和故障最大元素对故障类别和严重程度进行分类(表 1),以便运维人员根据重要程度实施维修和保养工作。

表 1 故障检测分级报警

告警颜色	告警等级	故障描述	建议措施
绿色	正常	运行正常	无
黄色	一级告警	潜在故障	关注运行
橙色	二级告警	轻微故障	合适时间必要检查
浅红	三级告警	明显故障	近期计划停机检修

3.2 寿命模型设计

试验设备工况数据生命周期较长,完整生命周期的数据采集以及样本的标注是一项十分繁琐和耗时的工作,需耗费大量存储资源。本研究利用多元高斯分布和长短时记忆神经网络实现了基于半监督的剩余寿命智能预测方法,此方法适用于新能源高速电机和底盘测功机等各类测试设备。寿命模型设计可分为以下 5 个步骤。

(1)数据采集。其数据集同样来源于数据服务器,采样频率设置为 f (可调),对于寿命预测模型。鉴于寿命预测模型关注长期趋势预测,采样频率可适当降低以满足需求。

(2)采用多元高斯分布计算方法提取不同生命周期相似度特征。首先,根据已知生命周期的设备采集样本数据,计算每组生命周期样本的均值 μ_k 和协方差矩阵 ζ_k ,计算方法如下:

$$\mu_k = \frac{1}{m_k} \sum_{i=1}^{m_k} x_k^{(i)} \quad (4)$$

$$\zeta_k = \frac{1}{m_k} \sum_{i=1}^{m_k} (x_k^{(i)} - \mu_k)(x_k^{(i)} - \mu_k)^T \quad (5)$$

式中: μ_k 为声明周期样本均值, ζ_k 为协方差矩阵, m_k 为 k 阶段样本总数量, $x_k^{(i)}$ 为 $F \times T$ 维的二维矩阵,是 k 阶段的第 i 个样本在连续 T 个时间点采集的 F 个特征

数据。

根据均值和协方差矩阵,可计算新未知生命周期样本 x 与每个已知生命周期设备运行状况的相似度,其计算公式可表示为:

$$p_k(x) = \frac{1}{(2\pi)^{\frac{n}{2}} |\zeta_k|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \zeta_k^{-1} (x - \mu_k)\right) \quad (6)$$

式中: $p_k(x)$ 为样本 x 与 k 阶段设备运行特征相似度, n 表示输入向量 x 的维度,即数据的特征数量。

最后得到未知样本 x 与每个阶段相似度向量:

$$p_k(x) = \{p_1(x), p_2(x), \dots, p_k(x)\} \quad (7)$$

假设 $p_n(x)$ 为 $p(x)$ 中最大的元素, L_{n-1}, L_n, L_{n+1} 分别是 $n-1, n, n+1$ 连续 3 个阶段设备的剩余寿命。若 $p_{n+1}(x) > p_{n-1}(x)$, 则未知样本剩余寿命标签的计算公式可表达为:

$$L_x = \frac{L_n \cdot p_n(x) + L_{n+1} \cdot p_{n+1}(x)}{(p_n(x) + p_{n+1}(x))} \quad (8)$$

若 $p_{n+1}(x) < p_{n-1}(x)$, 则未知样本剩余寿命标签的计算公式可表达为:

$$L_x = \frac{L_{n-1} \cdot p_{n-1}(x) + L_n \cdot p_n(x)}{(p_{n-1}(x) + p_n(x))} \quad (9)$$

(3)特征工程与数据集构建。首先将采集的连续时间内试验设备运行数据按时间片进行划分,设置时间片长度为 T (可调节)。对每种数据类型的每个时间片内的数据进行特征提取,提取内容主要包括最大值、最小值、均值、方差、置信区间、差分特征以及通过傅里叶变换得到的频域特征向量^[13]。

以步骤(2)中得到的剩余寿命值作为数据集标签,以目标时间片前 l 个时间片的特征向量作为输入构建数据集,其中 80% 为训练集,其余 20% 为测试集。

(4)剩余寿命预测的深度学习神经网络模型构建。剩余寿命预测模型包括循环神经网络模块、全连接神经网络模块以及参数优化模块,如图 4 所示。

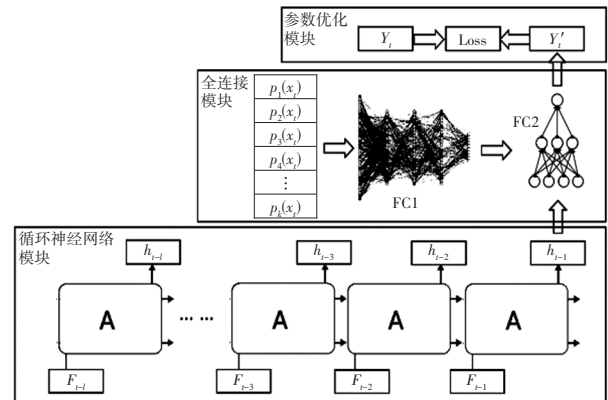


图 4 剩余寿命预测模型

在神经网络模块中,以每个A为一个记忆单元,共有 l 个记忆单元。 F_{t-1} 表示预测目标时间片 t 的前第 l 个时间片的特征向量, h_{t-1} 到 h_{t-l} 表示每个记忆单元的中间输出,将最后一个记忆单元的中间输出,即 h_{t-1} ,作为神经网络模块的输出^[14]。

在全连接模块中,全连接模块中, x_t 为时间步 t 的输入特征向量, $p_k(x_t)$ 为第 K 个阶段的每个设备运行数据计算相似度,全连接层(Fully Connected Layer, FC)用于将循环层的输出。根据步骤(2),将预测目标时间片 t 的样本数据与已知的 K 个阶段的每个设备运行数据计算相似度,得到相似度向量:

$$P(x_t) = \{p_1(x_t), p_2(x_t), \dots, p_K(x_t)\} \quad (10)$$

将其作为FC1全连接神经网络的输入,将FC1的输出与神经网络模块的输出 h_{t-1} 合并,作为FC2的输入,最终将FC2的输出为 Y'_t 。

最后,在参数优化模块中, Y'_t 为剩余寿命的预测值, Y_{QUOTE_t} 为剩余寿命的真实值,Loss为损失函数,用于计算预测误差。根据损失函数(如平均绝对值误差、均方误差或均方根误差),计算真实值标签 Y_{QUOTE_t} 与预测值 Y'_t 之间的误差,通过梯度下降与反向传播更新参数^[15],如图5所示。

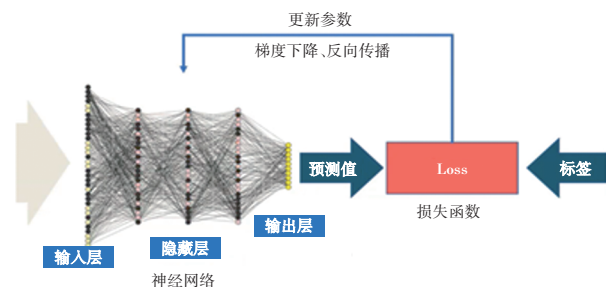


图5 模型参数优化

(5)测试集验证与实际应用。完成步骤(4)后,通过步骤(2)构建的测试集进行验证,直至测试集的损失函数值低于阈值 ε ,并保存训练完成的模型。在实际应用过程中,输入数据格式需与训练集和验证集格式一致,得到的预测结果则作为最终设备剩余寿命的预测值。

4 预测性维护系统应用效果

为验证系统有效性,选取同品牌、同型号、同年份的底盘测功机作为验证样本,并对已知特定故障的底盘测功机进行预测诊断(如电机前盖轴承故障、电机后盖轴承故障、轴承外圈故障、轴承滚珠故障以及轴系不平衡)。诊断结果百分比统计结果显示,I期模型诊断准确率达78%以上。如图6所示,对于寿命预测系统,由于缺少最终装备状态数据,以关键轴承件作

为预测目标。基于国际故障预测与健康管理协会的PRONOSTIA标准数据,模型测试准确率达到了85%以上。随着后续训练数据进一步完善,准确率及覆盖面将进一步提升。

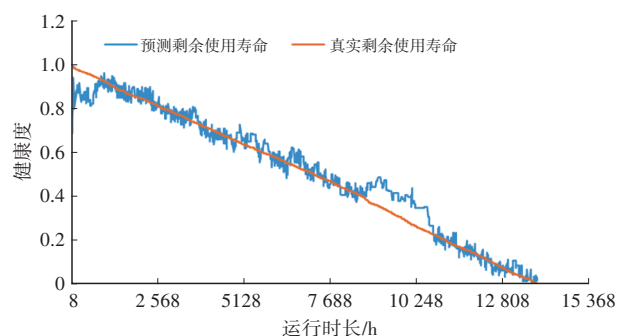


图6 寿命预测结果

5 结束语

本方案针对具体研发场景进行开发,融合了小波变换、卷积神经网络、多元高斯分布以及长短时记忆神经网络等关键技术,结合深度学习算法,实现目标结果的预测性呈现。显著降低了对海量标签数据的过度依赖,为工况多变的汽车研发设备预测维护提供了可靠解决方案。该预测性诊断系统可结合用户具体要求开发上位显示界面,实现设备状态总览、详细状态和参数信息浏览、快速点检等功能。此外,该系统可以支持设备专家通过数据趋势进行人工智能诊断,提前预防故障或者进一步优化预测模型。系统可根据需求规划报警页面,展示报警级别和故障信息,实现分级报警和具体故障定位,为运维人员提供清晰的信息支持,大幅度提升运维效率。在寿命预测方面,可实现单台设备的剩余寿命检测,为设备大修、保养、投资提供有力的决策依据,为汽车研发设备中测功机类的设备预测性维护提供了数智化的解决方案。

然而,本方案试验数据的多样性还有待提高,需进一步扩大数据集的采集范围,同时模型的泛化能力也需进一步提升,以适应更多应用场景。未来研究将进一步提升数据全面性,对采集到的数据进行深入分析,提取更有价值的信息。针对不同设备类型,对模型进行优化与调整,提高预测精度。

参考文献

- [1] 张国萍. 基于大数据的机械设备预测性维护系统研究[J]. 中国机械, 2023 (36): 61-64+69.
- [2] 程伦新, 王学良, 王劭博. 电机预测性维护系统应用研究[J]. 机电信息, 2024 (14): 20-25.
- [3] 李敏. 基于优化并行二维卷积神经网络的滚动轴承智能

- 故障诊断方法研究[D]. 西安: 长安大学, 2023.
- [4] 刘益豪, 石宇强. 基于注意力机制的CNN-BiLSTM复杂设备剩余寿命预测[J]. 机械设计, 2024(S1): 58-63.
- [5] 黄庆归. 基于小波包和LSTM神经网络技术的机器人预测性维护策略研究[J]. 设备管理与维修, 2024(1): 67-71.
- [6] 陈劲. 工业4.0智能传感器网络在生产监测与预测中的应用[J]. 信息系统工程, 2024(10): 36-39.
- [7] 孙若依, 黄明, 孙顺苗, 等. 基于数字孪生的自动化单元预测性维护参考框架[J]. 机床与液压, 2024(18): 110-115.
- [8] 何全添. 汽车底盘测功机检测设备的结构原理[J]. 内燃机与配件, 2020(2): 129-130.
- [9] 黄扣. 基于深度学习的旋转类机械预测性维护方法研究[D]. 镇江: 江苏科技大学, 2021.
- [10] HILMI A Z ,KHAIRUNNISA H ,ABDUL K A W. Integrated Failure Analysis Using Machine Learning Predictive System for Smart Management of Medical Equipment Maintenance[J]. Engineering Applications of Artificial Intelligence, 2023(125): 112551.
- [11] 樊超, 王帆. 可解释的小波卷积神经网络机械故障诊断方法[J/OL]. 振动工程学报, (2024-11-4)[2025-04-17]. <http://kns.cnki.net/kcms/detail/32.1349.TB.20241101.1704.006.html>.
- [12] 石碧波. 基于改进长短记忆网络的智慧工厂中设备故障预测[J]. 工业控制计算机, 2024(8): 105-106+109.
- [13] YANG L ,WEIGANG W ,YIHAO B, et al. Self-Supervised Feature Extraction via Time-Frequency Contrast for Intelligent Fault Diagnosis of Rotating Machinery[J]. Measurement, 2023(210): 112551.
- [14] LIU X, CHENG W, XING J, et al. Predictive Maintenance System for High-End Equipment in Nuclear Power Plant Under Limited Degradation Knowledge[J]. Advanced Engineering Informatics, 2024(61): 102506.
- [15] 唐侯清. 基于卷积神经网络的电机轴承故障诊断研究[D]. 南宁: 广西大学, 2023.

(责任编辑 梵玲)