

# 基于数据驱动的核电站主给水泵故障预测研究

张国辉, 骆志平

(中国原子能科学研究院, 北京 102413)

**摘要:** 目前, 核电站设备传感器每天都会产生大量的监测数据, 但这些数据的利用程度较低, 对于利用监测数据进行核电站重要设备的故障预测研究还处于探索阶段。针对这种情况, 本文以核电站主给水泵作为研究对象, 将表征主给水泵运行状态的各类监测数据进行预处理和降维, 进而通过多个选定的机器学习模型预测设备在未来是否会发生故障。通过对预测模型的效果评估发现, 长短时记忆网络模型(LSTM模型)具有较好的预测精度。当模型预测结果超过阈值时发出预警信息, 提醒核电站运维人员加强关注, 及时采取故障诊断和维修措施, 以有效防止因设备的突然故障停运造成较为严重的后果, 保证核电站的安全和经济运行。

**关键词:** 核电站; 主给水泵; 机器学习; 故障预测; 拟合

中图分类号: TL48; TP183

文献标志码: A

文章编号: 1000-6931(2024)09-1982-07

doi: 10.7538/yzk.2023.youxian.0814

## Data-driven Based Fault Prediction of Main Feedwater Pump in Nuclear Power Plant

ZHANG Guohui, LUO Zhiping

(China Institute of Atomic Energy, Beijing 102413, China)

**Abstract:** At present, nuclear power plant equipment sensors generate a large amount of monitoring data every day, but the utilization of these data is relatively low. Research on using monitoring data for fault prediction of important equipment in nuclear power plants is still in the exploratory stage. In response to this situation, this article takes the main feedwater pump of nuclear power plants as the research object, preprocesses the operation status data, reduces the various monitoring data dimensions, and then predicts whether the equipment will malfunction in the future through multiple selected machine learning models. The selected models are Linear model, support vector machine (SVM) model, and LSTM model. For the fault diagnosis of the main feedwater pump, the discrimination criterion is that the vibration signal of the feedwater pump bearing exceeds the threshold. When the predicted results of the model exceed the threshold, an early warning message is issued to remind the operation and maintenance personnel of the nuclear power plant to strengthen their attention, take timely fault diagnosis and maintenance measures, and prevent serious consequences caused by sudden equipment failure and shutdown, which will affect the safe operation of nuclear power plants. Specifically, this study utilized the operating parameters of the main feedwater pump during operation, which are more than ten parameters other than the vibration signals of the feedwater pump bearings. Through a predictive model, the vibration situation of the feedwater pump bearings was predicted, and the fault

status of the main feedwater pump was determined based on the vibration prediction signals to evaluate whether the equipment can operate for a long time. After preprocessing and feature selection, the selected dataset was trained and validated against traditional data processing models and currently popular deep learning models. After evaluation, it is found that the deep learning model LSTM has more accurate prediction results, with mean square error and goodness of fit meeting the required range and could better fit the actual operation of the equipment. At the same time, by using the ridge regression algorithm, the parameters that have a significant impact on the normal operation of the main feedwater pump can be analyzed. In the actual work of the equipment, it can help operation and maintenance personnel find the cause of faults and improve the quality of equipment operation and maintenance. The historical data used in this study mainly cover common typical faults of the main feedwater pump. In the future, it is necessary to continue collecting other types of fault data for model training and validation, so that the model can cover all possible faults that may occur in the main feedwater pump. Overall, the research prospects for fault prediction of such large-scale equipment are very broad.

**Key words:** nuclear power plant; main feedwater pump; machine learning; fault prediction; fitting

核电站主给水泵是非常重要的大型机电设备,用于向蒸汽发生器输送所需压力和流量的给水,并且在机组热备用、启动、运行以及停机等工况下维持蒸汽发生器所需的水位,以保证蒸汽发生器的可用性,从而导出反应堆功率运行时的热量和停堆后的余热。主给水系统不执行核安全相关的功能,但在正常工况下对于一回路热量的导出至关重要。在失去主给水的情况下,若辅助给水或启动给水不能正常启动,有可能导致一回路超温超压。

对于主给水泵,为了保证其安全可靠地运行,依然采用 20 世纪 90 年代初以来广泛使用的纠正性维修和预防性维护策略。这两种维护策略无法在设备故障之前判断出设备的异常运行状态,很难提前制定适当的维护计划。目前,利用设备运行监测数据,预警设备的故障情况,在国内外已有相关研究。2005 年,支持向量机(SVM)模型崭露头角。与神经网络相比,SVM 无需调参,模型训练更高效,更易获得全局最优解。委内瑞拉的 Rocco 等<sup>[1]</sup>将单分类 SVM 和多分类 SVM 组合成层次结构的分类器,能够辨识核电系统中暂态过程的异常。核反应堆浸没在水中以保持冷却,其高温高压和辐射危害使得无法对压力容器和堆内部件进行直接的人工定期检查。2017 年,美国的 Chen 等<sup>[2]</sup>提出了一种基于朴素贝叶斯数据融合方案和卷积神经网络(CNN)的核反应堆裂纹检测方法(命名

为 NB-CNN 方法)。该 NB-CNN 方法利用 CNN 提取核反应堆视频中捕获的各个视频帧的视觉特征,并利用朴素贝叶斯数据融合方案聚合从每个视频帧中提取的信息。NB-CNN 方法实现了 98.3% 的命中率。深度神经网络(DNN)具有比浅层神经网络更强的模式识别能力,并且在历史数据量足够大的情况下其准确率明显更高,DNN 也已应用于剩余使用寿命(RUL)的预测。韩国的 Utah 等<sup>[3-4]</sup>对比了包括 KNN(K 近邻算法)、决策树、随机森林、SVM 在内的传统机器学习与 DNN 对电磁阀剩余寿命的预测性能,证实了深度的网络结构可以提高模型预测精度。针对长序列数据进行学习时,常规循环神经网络(RNN)存在梯度消失和长期依赖问题,而改进 RNN-LSTM 很大程度上推动了该领域的研究进程。Yang 等<sup>[5-8]</sup>利用 LSTM 对 LOCA、SGTR 和 MSLB 等事故进行了故障诊断。湖南大学的余兢克等<sup>[9]</sup>构建了 CNN、LSTM 和卷积 LSTM(ConvLSTM)的组合,用于核电站冷却剂损失事故(LOCA)的故障诊断和事故后预测。因 ConvLSTM 具有有效的特征确定和提取的优点,被应用于 LOCA 案例的分类。通过 CNN 和 LSTM 的协同提高了预测精度。这种混合模型被证明是功能性的、准确的和自适应的,为应急响应提供快速的事事故判断和可靠的决策依据。

核电站主给水泵大量使用各类传感器,以实

时获取设备的运行状态和健康状态。这些传感器每时每刻都在产生数据,对于长期运行的设备,将会积累大量的设备监测数据,目前这些数据还无法得到有效利用<sup>[10]</sup>,未应用于设备的预测性维护。若对这些监测数据进行处理,再通过合适的驱动模型来预测设备的运行状态,确定何时需要维护操作,在设备故障之前维修人员提前介入维护,能极大程度地提高设备的运行可靠性,同时降低维护成本、缩短意外停机时间并延长设备的使用寿命,更能有效提升核电站的安全水平。

本研究选取目前已较为成熟的3种预测模型,即 Linear 模型(线性回归模型)、SVM 模型以及 LSTM 模型,分别对主给水泵故障情况进行预测,并通过均方误差和拟合优度对模型进行精度判别,以确定合适的故障预测模型。实际应用中,利用历史数据的先验信息,使选定的模型能够在

设备故障前的一段时间内提前预警,帮助电厂作出运维方式的决策,进而降低设备突然发生故障后导致的风险和损失。

## 1 故障预测思路

核电站每台机组设置3台主给水泵,每台主给水泵组包括前置泵、给水泵、电动机、齿轮箱等部件,主给水泵结构示意图如图1所示。电动机带动左侧的前置泵,右侧连接齿轮箱,通过齿轮箱升速后带动给水泵旋转供水。主给水泵运行期间,监视其运行状态的传感器种类和数量较多,如机械密封循环液温度、轴承金属温度、齿轮箱轴承金属温度、前置泵轴承振动、电机定子绕组温度、电机冷却装置进风温度、泵转速、润滑油压力和温度、传输介质温度、给水泵轴承振动等16个监测参数,监测点如图1中各箭头所指位置。

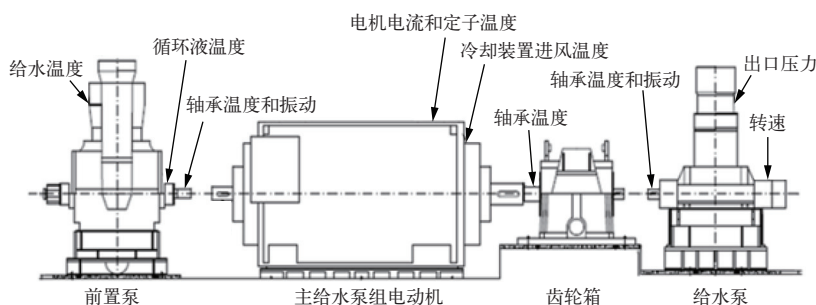


图1 主给水泵结构示意图及监测参数

Fig. 1 Structural diagram of main feedwater pump and monitoring parameters

对于主给水泵的故障判别,采用给水泵轴承振动信号超过阈值作为判别标准,该信号的测点如图1中轴承温度和振动箭头所指位置。在转动机械设备中,设备振动信号中包含了较为丰富的故障信息,任何机械设备在运转中若出现了内部故障,大多时故障会体现在振动异常。因此,对于旋转机械设备,利用振动监测信号变化对设备故障状态判别是当前国内外普遍应用的方法<sup>[11-12]</sup>。

本研究利用主给水泵运行期间的运行参数,这些参数为除给水泵轴承振动信号以外的其他十多个参数,通过模型预测给水泵轴承的振动情况,并根据振动预测信号判断主给水泵的故障状态,以评估设备是否可长期运行。在预测模型中,无需考虑给水泵轴承振动信号与其他监测参数之间的物理机理,而是将监测参数作为输入信号输入

预测模型,将模型预测值和给水泵轴承振动实测信号比较,以训练和验证预测模型。获得精度满足要求的预测模型之后,利用历史监测数据即可预测下一阶段的给水泵轴承振动信号。预测模型能预测多远时刻的振动信号,需要调整模型参数不断验证。

## 2 预测模型

### 2.1 模型介绍

#### 1) Linear 模型

线性回归是一种简单且成熟的数据分析技术,可以利用相关的已知数据集来预测某个变量的值,它以数学方式将因变量和自变量建模为线性方程,建模速度快,计算简单,对于大量数据仍能得到较快的计算速度。但也存在不能处理非线性

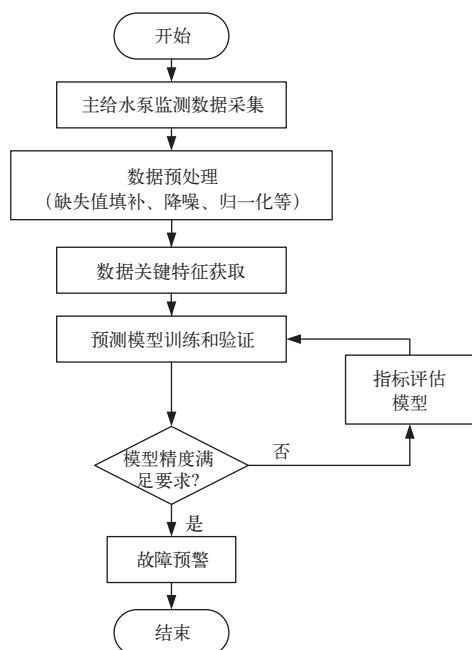


图2 故障预测流程

Fig. 2 Fault prediction process

性问题以及预测结果误差较大的缺点。在实际应用方面, Linear 模型可用便于理解的数学公式来预测事物的变化, 如对于工厂产生的大量原始数据, 可通过 Linear 模型对其进行分析, 得出能指导生产和管理的有用结论。许多行业的从业人员均可使用线性回归进行初步数据分析并预测未来的发展趋势。

对于数据变量  $x$  和  $y$ , 当只用 1 个  $x$  来预测  $y$  时, 就是一元线性回归。可列出如下方程:

$$y(x) = \omega x + b \quad (1)$$

对于给定的参数  $\omega$  和  $b$ , 该方程在坐标系内为一条直线。对于散落在坐标系内的数据点, 一元线性回归就是在找 1 条直线来尽可能拟合这些数据点。

如果  $x$  包括  $n$  个属性, 即  $x = (x_1; x_2; \cdots; x_n)$ , 其中  $x_i$  代表  $x$  的第  $i$  个属性值, Linear 模型可表示为通过一个线性组合来进行预测的方程, 即:

$$y(x) = \omega_1 x_1 + \omega_2 x_2 + \cdots + \omega_n x_n + b \quad (2)$$

一般用向量形式表示:

$$y(x) = \omega^T x + b \quad (3)$$

其中,  $\omega = (\omega_1; \omega_2; \cdots; \omega_n)$ 。  $\omega_i$  值的大小反映了对应属性的重要程度。

以上方程就代表多元线性回归。

## 2) SVM 模型

SVM 模型是一种二分类模型, 在分类和回归问题中有广泛的应用。其基本模型是定义在特征空间上的间隔最大的线性分类器, 即通过间隔最大化原则进行分类。通过核函数的选择, SVM 模型可以处理非线性问题, 还能处理高维数据, 泛化能力较强, 具有较好的鲁棒性和可解释性等。但 SVM 模型也存在缺点, 如计算复杂度高、对噪声数据敏感等, 使用 SVM 算法进行数据分析前, 需要对数据进行预处理, 去除噪声数据, 保证数据的质量。

## 3) LSTM 模型

LSTM 模型本质上是一种改进形式的 RNN 模型。RNN 模型在训练过程中会出现梯度消失的问题, 即当输入的序列数据长度过长时, 距离当前时刻较远的数据的作用将被弱化甚至完全被覆盖, 进而无法学习之前较远时刻的序列数据。LSTM 模型在 RNN 模型的基础上通过门控单元 (Gates) 来解决 RNN 出现的梯度消失问题, 使得 LSTM 模型可以真正有效地学习更长的时间序列。在 RNN 模型的结构基础上, LSTM 模型增加了 3 个门控单元, 分别为输入门 (Input Gate)、输出门 (Output Gate) 和遗忘门 (Forget Gate), 再通过设定权重控制各门控单元的作用。如输入门通过激活函数 sigmoid 决定哪些信息将会被新输入, 输出门根据当前时刻输入、上一时刻隐藏层的状态以及当前时刻最终的记忆单元状态决定该时刻的输出, 遗忘门通过激活函数 sigmoid 决定哪些信息将会被遗忘。在时刻  $t$ , LSTM 模型结构内部运算公式如下:

$$f_t = \text{sigmoid}(W_f[h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \text{sigmoid}(W_i[h_{t-1}, x_t] + b_i) \quad (5)$$

$$o_t = \text{sigmoid}(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$c'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$c_t = f_t c_{t-1} + i_t c'_t \quad (8)$$

$$h_t = o_t \tanh(c_t) \quad (9)$$

其中:  $f_t$ 、 $i_t$ 、 $o_t$  分别为遗忘门、输入门和输出门的输出;  $W_*$  为递归连接权重;  $b_*$  为偏置量;  $c'_t$  为当前输入的记记忆单元状态;  $c_t$  为当前时刻最终的记记忆单元状态;  $x_t$  为当前时刻的输入向量;  $h_{t-1}$  为上一时刻的输出向量;  $h_t$  为当前时刻的输出向量;



sigmoid 和 tanh 为激活函数。

LSTM 模型的结构如图 3 所示。

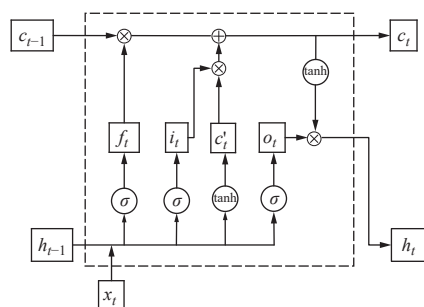


图 3 LSTM 单元结构

Fig. 3 Schematic diagram of LSTM unit

## 2.2 模型评估和故障预警

将采集得到的数据集分为训练集和验证集,训练集用于构建模型,确定模型中的各类参数,验证集用来验证模型预测结果的误差大小,根据误差继续优化预测模型。本研究采用均方误差(MSE)、平均绝对误差(MAE)以及拟合优度( $R^2$ )这 3 个指标来验证模型的精度和泛化能力。MSE 的值越小,说明模型的预测结果越接近真实值,同时  $R^2$  值越接近 1,表明模型的拟合效果越好。对于主给水泵,一些监测数据可能在某个时间点有较大的波动,但总体上会以监测数据平均趋势变化为判断依据,因此选择 MAE 作为辅助评估指标以减小离群点的影响<sup>[13]</sup>。

在实时预测中,需通过提前选定阈值的方法来识别异常信号。对于主给水泵,常用振动绝对标准 ISO2372 判断运行状态,一般限值为 7.1 mm/s。但主给水泵在实际的长期运行期间其轴承振动不能太高,应取一个低于限值的值  $A$  为预警值,  $A$  由运维经验确定。当某一时刻,如果给水泵轴承振动预测值大于  $A$ ,系统发出报警,达到提前预警设备故障的目的<sup>[14]</sup>。

## 3 监测数据采集和处理

### 3.1 数据采集

从某核电厂主给水系统主给水泵 A 运行监测数据中选取一个时间段的数据作为原始数据集,数据集的起止时间为 2023 年 5 月 23 日 18:12 至 2023 年 6 月 5 日 19:05,数据采集间隔为 100 ms,其中包括主给水泵正常运行期间振动正常和故障振动的数据点,故障主要包括转子偏心、轴承松

动、泵基础和支架缺陷、轴承润滑油型号不合适、机封循环液温度过高或过低等。从以上时段的数据中选取 88 组数据,每组数据为 1 个 150 s 的连续数据段,采样率为 10 Hz,包括 1 500 个数据点。其中 68 组数据用于训练模型,作为训练集,20 组数据用于验证模型,作为验证集。

### 3.2 数据处理

对于从主给水泵各传感器采集到的运行数据,由于监测设备或数据采集系统的因素,可能存在异常值或缺失值,如对这些数据不进行清洗处理,可能会影响模型计算的精度。因此,要通过缺失值填补、小波包降噪以及归一化处理等处理方法提高数据质量,保证数据的准确性和完整性。同时,主给水泵作为重要的大型机电设备,不同类别的监测数据较多,影响设备运行的因素较多,而各因素的影响程度却不同,因此,还需要对相关的信号降维,去除相关性较小的影响因素,从而降低模型复杂度,有效减少计算量<sup>[15]</sup>。

### 3.3 数据关键特征获取

对于主给水泵的十多个运行监测参数,其中部分参数与给水泵振动信号之间的内在联系微小甚至没有。利用线性回归和岭回归收缩方法,对预测模型输入参数进行选择并排除多重共线性参数,从而降低预测模型的输入维度,获取数据关键特征,以得到较高精度的预测模型<sup>[16]</sup>。通过判别,在给水量一定的情况下,得出如下 7 个参数的重要程度较高:机械密封循环液温度( $T_1$ )、止推轴承非驱动端金属温度( $T_2$ )、前置泵轴承体振动( $V$ )、泵转速( $S$ )、给水泵径向轴承金属温度( $T_3$ )、润滑油温度( $T_4$ )以及给水温度( $T_5$ ),如表 1 所列,其中 ID 指重要性程度。

表 1 归一化的相对重要性因子

Table 1 Normalized relative importance factor

序号	参数	ID
1	$T_1$	0.05
2	$T_2$	0.05
3	$V$	0.145
4	$S$	0.053
5	$T_3$	0.054
6	$T_4$	0.054
7	$T_5$	0.05

4 模型预测

4.1 预测指标评估

利用以上降维后的数据集,对 Linear 模型、SVM 模型以及 LSTM 模型分别进行训练,得到最终的预测模型,其中 LSTM 模型的迭代次数接近 100 次。本文利用验证数据集中的 1 组故障数据对模型进行测试,主要评估均方误差 MSE、平均绝对误差 MAE 以及拟合优度  $R^2$  这 3 个指标。具体指标数值如表 2 所列。

表 2 3 种预测模型的 MSE、MAE 和  $R^2$   
Table 2 MSE, MAE and  $R^2$  of three prediction models

预测模型	MSE	MAE	$R^2$
Linear	0.252 456	0.197 234	0.695
SVM	0.225 064	0.181 136	0.803
LSTM	0.089 662	0.074 504	0.948

4.2 实际预测效果

综上可见,相较于传统的 Linear 模型和 SVM 模型,LSTM 模型在均方误差和拟合优度两个方面具有明显优势。LSTM 模型具有更高的精确度和更优的拟合度,预测的数值更接近真实值,同时离散点对模型的精度影响也相对较小。3 个模型的预测效果如图 4 所示。从图 4 可看出,LSTM 模

型的预测值与真实值的拟合度明显优于 Linear 模型和 SVM 模型,也证明利用 LSTM 模型对长时间序列数据的处理存在优势。

5 总结

本文选取核电站主给水泵作为研究对象,利用影响设备运行的各类监测数据,通过一定的模型对其运行情况进行预测。以主给水泵轴承振动超标作为设备故障的判断依据,当模型预测的结果超过阈值时发出预警信息,提醒核电站运维人员加强关注,及时采取故障诊断和维修措施,防止因设备的突然故障停运造成较为严重的后果,影响核电站的安全和经济运行。选取的数据集经过预处理和特征选取后,对传统的数据处理模型和目前流行的深度学习模型进行训练和验证,评估后发现深度学习模型 LSTM 的预测结果更精确,均方误差小于 0.1,拟合优度大于 0.9,能较好地拟合设备的实际运行情况。同时通过岭回归算法,分析出对主给水泵正常运行影响较大的参数,在设备实际运行中,可以帮助运维人员查找故障原因,提高设备的运行和维护质量。

在设备的实际运行过程中,实时预测设备的故障状态并提前发出故障预警信号,对于核电站的安全运行和经济至关重要。而目前,现有的研究大多是关于故障诊断方面的,对于核电站设备的故障预测研究并不多见,尤其是涉及核电站大型机电设备的故障预测研究更少,其原因主要是这类设备结构较为复杂,影响因素众多,同时用于研究的故障数据难以收集。本研究所利用的历史数据主要覆盖主给水泵常见的典型故障,后续需要继续收集其他类型的故障数据用以模型的训练和验证,以使模型能覆盖主给水泵可能发生的所有故障。

参考文献:

[1] ROCCO S C M, ZIO E. A support vector machine integrated system for the classification of operation anomalies in nuclear components and systems[J]. Reliability Engineering & System Safety, 2007, 92(5): 593-600.  
[2] CHEN F C, JAHANSHAH M R. NB-CNN: Deep learning-based crack detection using convolutional neural network and Naïve Bayes data fusion[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4392-4400.




图 4 3 种模型的预测效果

Fig. 4 Prediction performance of three models

- [3] UTAH M N, JUNG J C. Fault state detection and remaining useful life prediction in AC powered solenoid operated valves based on traditional machine learning and deep neural networks[J]. *Nuclear Engineering and Technology*, 2020, 52(9): 1998-2008.
- [4] ZEMOURI R, GOURIVEAU R, ZERHOUNI N. Defining and applying prediction performance metrics on a recurrent NARX time series model[J]. *Neurocomputing*, 2010, 73(13-15): 2506-2521.
- [5] YANG J, KIM J. An accident diagnosis algorithm using long short-term memory[J]. *Nuclear Engineering and Technology*, 2018, 50(4): 582-588.
- [6] HINCHI A Z, TKIOUAT M. Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network[J]. *Procedia Computer Science*, 2018, 127: 123-132.
- [7] 龚安, 马光明, 郭文婷, 等. 基于 LSTM 循环神经网络的核电设备状态预测[J]. *计算机技术与发展*, 2019, 29(10): 41-45.  
GONG An, MA Guangming, GUO Wenting, et al. Nuclear power equipment status prediction based on LSTM recurrent neural network[J]. *Computer Technology and Development*, 2019, 29(10): 41-45(in Chinese).
- [8] SHE J, SHI T, XUE S, et al. Diagnosis and prediction for loss of coolant accidents in nuclear power plants using deep learning methods[J]. *Frontiers in Energy Research*, 2021, 9: 665262.
- [9] 余兢克, 薛时雨, 孙培伟, 等. 基于深度学习的核电站事故预测及故障诊断方法[J]. *仪器仪表用户*, 2019, 26(12): 39-44.  
SHE Jingke, XUE Shiyu, SUN Peiwei, et al. The application of LSTM model to the prediction of abnormal operation in nuclear power plants[J]. *Instrumentation*, 2019, 26(12): 39-44(in Chinese).
- [10] 许勇, 蔡云泽, 宋林. 基于数据驱动的核电设备状态评估研究综述[J]. *上海交通大学学报*, 2022, 56(3): 267-278.  
XU Yong, CAI Yunze, SONG Lin. Review of research on condition assessment of nuclear power plant equipment based on data-driven[J]. *Journal of Shanghai Jiao Tong University*, 2022, 56(3): 267-278(in Chinese).
- [11] 张鑫. 关于机泵振动状态监测提升设备预知维修管理水平研究[J]. *中国设备工程*, 2022(20): 178-180.  
ZHANG Xin. Research on monitoring the vibration state of pump to improve the management level of predictive maintenance of equipment[J]. *China Plant Engineering*, 2022(20): 178-180(in Chinese).
- [12] 张永伟, 云再鹏, 陈宏同. 电气设备振动故障实时监测预警方法[J]. *自动化与仪表*, 2023, 38(11): 21-24, 83.  
ZHANG Yongwei, YUN Zaipeng, CHEN Hongtong. Real-time monitoring and warning method for vibration faults of electrical equipment[J]. *Automation & Instrumentation*, 2023, 38(11): 21-24, 83(in Chinese).
- [13] 游东东, 黎家良, 刘高俊, 等. 基于贝叶斯 BiLSTM 模型的核电阀门传感器故障预警方法[J]. *华南理工大学学报(自然科学版)*, 2021, 49(12): 43-52.  
YOU Dongdong, LI Jialiang, LIU Gaojun, et al. Fault early warning method of nuclear valve position sensor based on Bayesian LSTM model[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2021, 49(12): 43-52(in Chinese).
- [14] 姚鹏飞, 王丹丹, 王瑞红. 基于 ANN 下拖拉机发动机扭矩预测模型的研究[J]. *农机化研究*, 2024, 46(5): 240-246.  
YAO Pengfei, WANG Dandan, WANG Ruihong. Research on tractor engine torque prediction model based on ANN[J]. *Journal of Agricultural Mechanization Research*, 2024, 46(5): 240-246(in Chinese).
- [15] 张煜东, 霍元铠, 吴乐南, 等. 降维技术与方法综述[J]. *四川兵工学报*, 2010, 31(10): 1-7.  
ZHANG Yudong, HUO Yuankai, WU Lenan, et al. Summary of dimension reduction technology and methods[J]. *Journal of Sichuan Ordnance*, 2010, 31(10): 1-7(in Chinese).
- [16] 马天男. 基于大数据的电网覆冰灾害预测与风险管理研究[D]. 北京: 华北电力大学, 2017.