

基于深度学习 LSTM-DBN 的水轮机振动故障 预测方法*

罗 毅, 武博翔

(华北电力大学控制与计算机工程学院 北京, 102206)

摘要 深度学习算法具有强大的时间序列预测能力以及可实时处理大数据海量样本的优势。针对水轮机系统振动故障诊断存在精度低、漏诊及难预测等问题,提出了一种基于深度学习长短时记忆(long short time memory, 简称 LSTM)网络结合深度置信网络(deep belief networks, 简称 DBN)的水轮机系统故障预测方法。将小波包能量带与时频域指标信息相结合,提取高维故障统计特征,利用 DBN 深层网络的自适应特征提取能力对原始故障数据进行高维特征表示,准确地判断故障种类,并凭借 LSTM 对时序信号强大的预测能力,预测出未来系统可能发生的振动故障。工程实验验证了该算法的有效性。

关键词 水轮机;深度学习;故障预测;长短期记忆网络;深度置信网络;小波包分解
中图分类号 TH17;TV73

引 言

近年来可再生能源迅猛发展,国家对水电建设越来越重视。根据《水电发展“十三五”规划》,2020 年我国水电总装机容量达到 3.8 亿 kWh,其中常规水电为 3.4 亿 kWh,抽水蓄能为 4 000 万 kWh,年发电量为 1.25 万亿 kWh,水电在电网中占比越来越高。水电机组设备在进行制造、安装及运行等过程中存在种种问题,将导致机组稳定性变差,使得机组振动摆度超标,从而损伤机组内部机械零件,发生严重的故障,对水利枢纽设备的安全性及稳定性造成影响。作为故障诊断的拓展领域,故障预测主要是根据系统过去和当前的状态来提前判断将要发生的故障,以便及时采取相应的补救措施。相对于水轮机故障诊断而言,故障预测研究不仅可以及早发现故障的原因和部位,提高机组运行的安全性和可靠性,而且可以变定期预防维修和事后诊断维修为视情预知维修,减少或避免设备在使用过程中发生重大恶性事件^[1-2]。

目前,故障诊断及预测的方法很多。深度学习作为人工智能的一个重要分支,是一种基于多层神经网络的机器学习方法,其能够自动将简单的特征组合成复杂特征,并使用这些组合特征解决问题,近

年来已成功应用于机器翻译、语音识别及计算机视觉等领域。LSTM 是具有代表性的深度学习技术之一,作为循环神经网络的一种变体,其特殊的细胞结构能够解决长期依赖等问题,适用于预测时间序列数据^[3-4]。DBN 通过采用逐层训练的方式,解决了深层次神经网络的优化问题,为整个网络赋予较好的初始权值,更适合处理一维离散数据^[5-6]。深度学习神经网络在故障预测方面获得了广泛应用^[7]。

池永为等^[8]提出一种基于多标签 LSTM 结合循环神经网络(recurrent neural network, 简称 RNN)的滚动轴承故障分类方法,适用于复杂振动信号分类,对于实现快速准确的旋转机械故障诊断具有应用价值。孟小凡等^[9]针对卫星姿控系统时间序列故障预测问题,给出了误差反向传播(back propagation, 简称 BP)神经网络和小波神经网络、小波分解-LSTM 网络相结合的故障预测方法,利用 LSTM 网络能选择性保留输入数据的特点,预测更准确,性能更优越。周奇才等^[10]结合深度学习模型 LSTM 循环神经网络,提出一种适用于盾构机的故障预测系统,系统的分层结构能够降低耦合度,提高预测系统的通用性,但对预测模型缺少改进,参数选择没有达到最优。于洋等^[11]针对多工况下滚动轴承故障声发射信号智能识别问题,提出了一种 LSTM 与迁移学

* 国家自然科学基金资助项目(52277216)

收稿日期:2020-09-13;修回日期:2020-10-23

习相结合的故障识别新方法,提高了故障识别效率。杜小磊等^[12]提出了一种基于深层小波卷积自编码器和 LSTM 的轴承故障诊断方法,利用深层特征训练 LSTM 网络,实验结果表明其特征提取能力和识别能力优于传统方法。

由于故障预测的难度较大,目前对水轮发电机组故障的研究主要关注于故障诊断,而在故障预测方面的研究相对较少。程宝清等^[13]提出小波频带分析与灰色理论相结合的方法,对水电机组进行故障预测,但对大量故障数据的处理能力不足。何理瑞^[14]根据水轮机常见振动故障特点,提出建立故障诊断专家系统,给出了状态检修建议,为制定检修计划、判断失效与否提供依据,但面临知识获取困难的问题。

针对水轮机故障预测需处理大数据海量样本的问题,笔者将历史故障数据的时频域统计指标、小波能量频带作为故障特征训练 DBN 网络,采用 LSTM 网络对采集到的振动信号进行时间序列预测,并利用训练好的 DBN 网络模型进行故障判别分类,称之为 LSTM-DBN 算法。该方法利用深度学习的优势和 LSTM 强大的时间序列预测能力对水轮机振动信号进行预测,由 DBN 对提取出的各项指标特征进行故障诊断分类。工程实验验证了该方法的有效性。

1 水轮机故障特征分析及数据处理

1.1 水轮机典型故障

目前,水电机组设备向着大型化、巨型化的方向发展,在设计、制造及安装等过程中会受到多方面因素的影响,致使其在运行时发生故障。水轮机系统振动故障主要包括水力振动、机械振动和电磁振动^[15],其典型振动故障如图 1 所示。

诱发故障的原因很多,对其故障特征的提取和分析一直是研究热点。除了考虑系统本身的机械特性之外,机械设备在运动状态下(正常和异常状态)都会产生振动和噪声。研究表明,振动和噪声的强弱及其包含的主要频率成分与故障的类型、程度及部位等密切相关。大多数机械设备是定速运转设备,各零部件的运动规律决定了其振动频率。由于是定速运转,其振动频率即为该零部件的特征频率,观测特征频率的振动幅值变化,可以了解该零部件的运动状态和劣化程度。

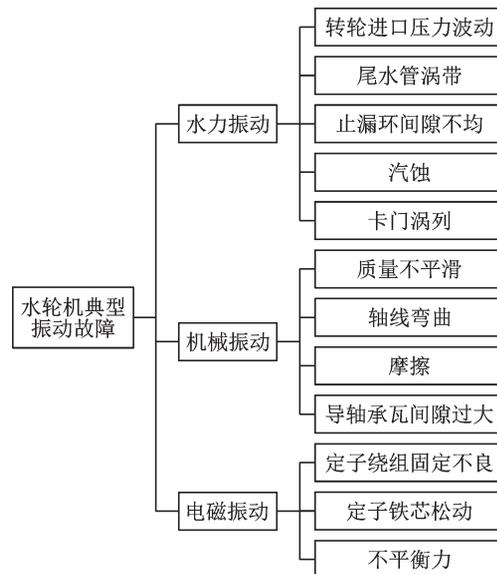


图 1 水轮机典型振动故障

Fig.1 Typical failure vibration of hydraulic turbine

1.2 多信息融合的故障特征提取

在建立预测模型之前,需要对原始数据进行预处理。传统方法如线性傅里叶滤波方法、指数平滑滤波器等,在对原始信号进行分解时,通常要在输出信号中明确给出信号的相移规则,使信号存在一定的损失。小波方法更多考虑了对信号进行有效的分解,而不是对信号进行过滤,使得小波方法可以将复杂的信号转换成有限带宽的基本信号,并以非常少的信息损失来重建这些信号。

笔者通过小波包 3 层分解,将信号无冗余、无疏漏地分解到合适的频带后,各频带具有与之相适应的能量范围,而故障信息就包含在信号的不同能量特征中。图 2 为导水轴承故障能量谱,图 3 为定子铁芯松动故障能量谱。

不同特征参量对各种故障的敏感程度不同。为增加单一信号特征信息的完备性,选择时频域指标如下:波形指标、峰值指标、脉冲指标、裕度指标、峭

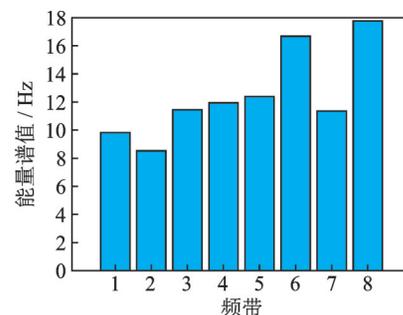


图 2 导水轴承故障能量谱

Fig.2 Energy spectrum of water guide gearing fault

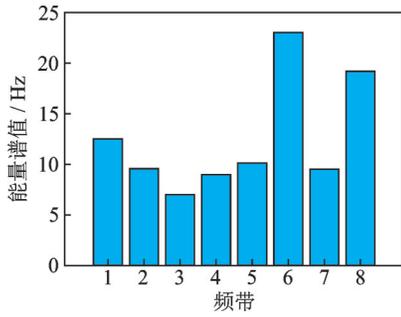


图 3 定子铁芯松动故障能量谱

Fig.3 Energy spectrum of loose stator core fault

度指标、重心频率、均方频率及频率方差等,连同小波包 3 层分解后的能量谱,共同作为故障的特征向量。离散时间序列的时频域统计指标如表 1 所示。

表 1 离散时间序列的时频域统计指标

Tab.1 Time - frequency domain statistical indicators of discrete time series

| 分析指标 | 表达式 |
|-------|--|
| 平均值 | $\bar{x}_1 = \frac{1}{N} \sum_{i=1}^{N-1} x_i$ |
| 峰峰值 | $x_3 = \max(x_i) - \min(x_i)$ |
| 标准差 | $x_5 = \sqrt{\left(\sum_{i=1}^N (x_i - \bar{x}_1)^2 \right) / (N-1)}$ |
| 峭度 | $x_7 = \left(\sum_{i=1}^N (x_i - \bar{x}_1)^4 \right) / (N-1) x_5^4$ |
| 波形因子 | $x_9 = x_4 / x_2$ |
| 变异系数 | $x_{11} = x_5 / x_1$ |
| 中心频率 | $x_{13} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$ |
| 绝对均值 | $x_2 = \frac{1}{N} \sum_{i=1}^N x_i $ |
| 均方根值 | $x_4 = \left(\frac{1}{N} \sum_{i=0}^{N-1} x_i^2 \right)^{\frac{1}{2}}$ |
| 偏度 | $x_6 = \left(\sum_{i=1}^N (x_i - \bar{x}_1)^3 \right) / (N-1) x_5^3$ |
| 脉冲因子 | $x_8 = \max(x_i) / x_2$ |
| 波峰因子 | $x_{10} = \max(x_i) / x_4$ |
| 均值频率 | $x_{12} = \left(\sum_{k=1}^K 5(k) \right) / K$ |
| 均方根频率 | $x_{14} = \sqrt{\frac{\sum_{k=1}^K f_k^2 x(k)}{\sum_{k=1}^K x(k)}}$ |
| 标准差频率 | $x_{15} = \sqrt{\frac{\sum_{k=1}^K (f_k - x_{13})^2 x(k)}{\sum_{k=1}^K x(k)}}$ |

2 基于 LSTM-DBN 的水轮机振动故障预测算法

2.1 预测算法流程

为了对水轮机系统振动故障进行预测,笔者以小波包能量带结合时频域指标信息,提取高维的统计特征,将多个信息作为 DBN 神经网络的故障训练特征,充分发挥深层网络的特征提取优势,使用 LSTM 网络对采集到的振动信号进行时间序列预测,并利用训练好的 DBN 网络进行故障判别分类。LSTM-DBN 故障预测过程如图 4 所示。

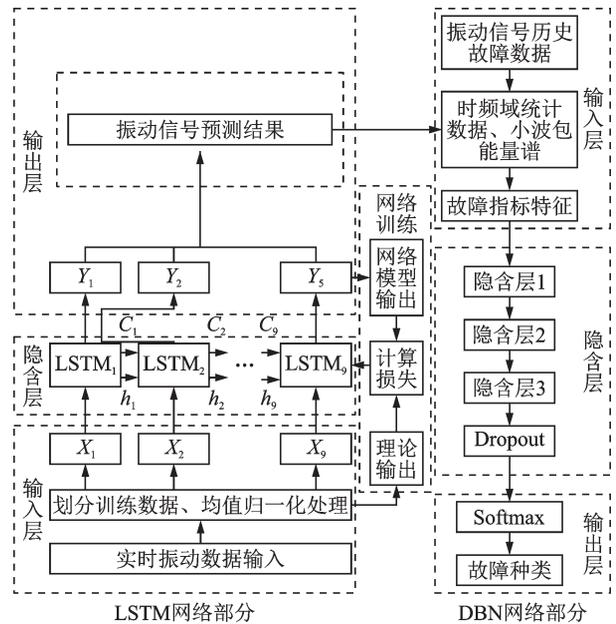


图 4 LSTM-DBN 故障预测过程

Fig.4 Fault prediction process based on LSTM-DBN

由图可知,基于 LSTM-DBN 水轮机振动故障预测方法的具体步骤如下:

- 1) 将实时振动数据输入 LSTM 网络,预测后面时间段内的振动信号;
- 2) 监测并采集获取水轮机振动摆度信号,将历史振动故障数据进行特征提取后作为输入数据,故障类型作为输出,训练 DBN 网络;
- 3) 利用小波包分解方法对步骤 1 预测出的信号进行分析处理,得到能量谱及时频域指标作为特征参数,输入用历史故障数据训练的 DBN 网络进行诊断分类,得到预测结果。

2.2 网络参数选择及预测模型建立

LSTM 网络可以被层叠成深层网络结构。通

常 LSTM 模块的层数越多,其对高层次特征表示的能力就越强,但同时也会学习到样本数据中的噪声信息,对网络的预测能力造成极大的影响。为选择 LSTM 网络层数,这里将训练集完整训练一轮的次數 epoch 超参数设置为 100,保证其他参数一致,LSTM 模块层数分别设置为 1,2 和 3,不同 LSTM 模块层数下的网络训练指标如表 2 所示。

表 2 不同 LSTM 模块层数下的网络训练指标

Tab.2 Network training indicators under different LSTM module layers

| LSTM 模块层数 | 均方根误差 | 平均绝对百分比误差/% | 训练时间/s |
|-----------|---------|-------------|--------|
| 1 | 0.012 0 | 8.90 | 52 |
| 2 | 0.012 0 | 8.87 | 87 |
| 3 | 0.028 2 | 26.77 | 108 |

可以看出,增加 LSTM 模块层数,网络的训练时间也随之变长。双层 LSTM 网络在测试集样本上的预测精度比单层 LSTM 网络的预测精度稍高一些,但相差不大;当 LSTM 模块增大到 3 层时,网络的预测效果很不理想,与上述理论分析相一致。在可承受的网络训练时间范围内,应尽可能追求高精度的预测结果,因此最终建立的 LSTM 为双层 LSTM 网络。

在 DBN 网络中,为防止数据过拟合,对数据进行去均值化预处理,将预处理后的数据输入网络进行训练。结果最优的训练策略是采用 Xavier Initialization 进行权重初始化,批量尺寸为 16,优化方法采用 Adam 方式,初始学习率为 0.001,微调迭代周期为 240。通过采用 DBN 对时频域统计指标和小波包能量谱分类识别,并采用训练准确度和验证准确度进行衡量。为选择故障分类网络,对 100 组故障测试数据进行诊断分类,将 DBN 与不同的分类算法进行比较,表 3 为不同分类算法的准确度。由表可知,DBN 网络因其优秀的对高维数据特征提取能力,准确率明显高于其他比较算法。

表 3 不同分类算法的准确度

Tab.3 Accuracy of different classification algorithms

| 算法 | 测试数据/组 | 准确分类/组 | 准确率/% |
|-----|--------|--------|-------|
| BP | 100 | 78 | 52 |
| 决策树 | 100 | 85 | 87 |
| DBN | 100 | 99 | 99 |

3 工程实验与结果分析

为验证本研究基于深度学习 LSTM-DBN 的水轮机振动故障预测算法的有效性,以某水电站为研究对象,该水利枢纽工程装机容量为 5×6.9 MW 灯泡贯流式水轮发电机组,水轮机额定水头为 5 m,额定出力为 7.19 MW,额定流量为 $160.02 \text{ m}^3/\text{s}$ 。

选用该水电站 2 号机组涡带偏心故障信号数据为例,进行水电机组振动故障预测实验。水轮机在运行过程中,仅通过单一的振动频率时间序列预测后面一段时间内的水轮机振动信号,并以此判断可能发生的振动故障,及时采取检修措施。笔者基于 LSTM 网络预测不同时间后的水轮机振动幅度,如图 5 所示。

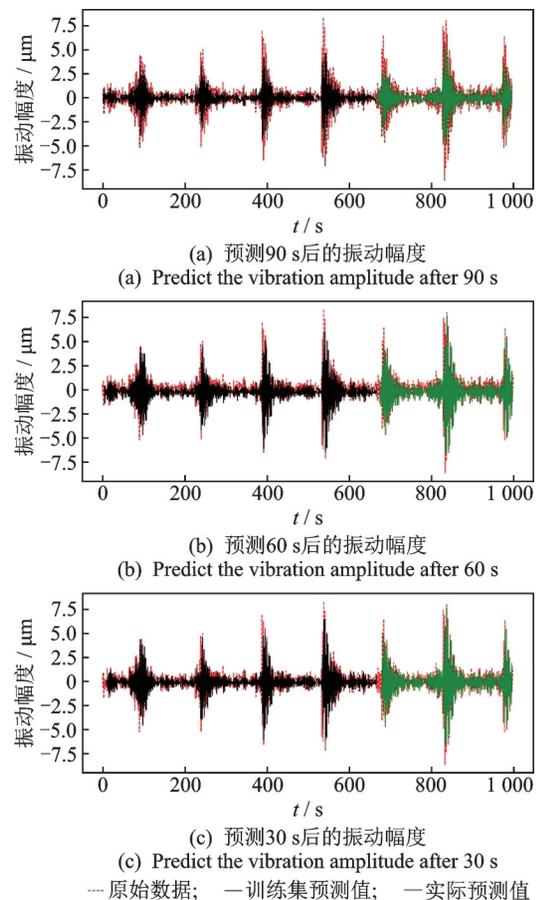


图 5 基于 LSTM 网络预测不同时间后的振动幅度

Fig.5 Vibration amplitude prediction with different time steps based on LSTM network

对预测后的结果进行均方根误差计算,如表 4 所示。

通过图 5、表 4 中的性能对比,同样训练数据下,提前预测时间越短,预测结果越接近实际振动趋势,故障预测结果更准确。考虑到实际情况,算法目的

表4 不同时间的均方根误差预测

Tab.4 Predict the RMSE at different times

| 提前预测时间/s | 均方根误差 |
|----------|-------|
| 90 | 1.48 |
| 60 | 0.88 |
| 30 | 0.73 |

是能够预测出故障种类即可。提前90 s预测结果均方根误差较大,数据处理后输入DBN网络得到的故障与实际不符;提前30 s预测结果虽然均方根误差更小,但提前时间较短。因此,选择采用LSTM网络进行60 s的振动幅度预测。

对图5(b)中预测出的绿色曲线进行特征提取,得到数据的时频域统计指标和小波包能量谱,预测结果的各项特征如表5所示。

表5 预测结果的各项特征

Tab.5 Characteristics of prediction results

| 特征项 | 数值 | 特征值 | 数值 |
|------|----------|--|----------|
| 峰峰值 | 2.047 5 | | 9.822 7 |
| 标准差 | 0.238 7 | | 8.542 7 |
| 方差 | 0.057 0 | | 11.451 9 |
| 峰值指标 | 8.583 5 | 3层分解后的 小波包能量谱 (2 ³ 个) | 11.952 8 |
| 裕度指标 | 14.664 4 | | 12.391 5 |
| 绝对均值 | 0.171 4 | | 16.680 0 |
| 有效值 | 0.238 5 | | 11.385 5 |
| 波形指标 | 1.391 7 | | 17.772 5 |
| 脉冲指标 | 11.945 3 | | |
| 峭度指标 | 6.222 2 | | |

将各项特征输入DBN网络模型中进行故障诊断分类,得到的故障结果显示为涡带偏心故障,与实际故障一致,验证了算法对水轮机振动趋势的预测能力。笔者以涡带偏心故障为例进行仿真实验,结果证明了基于LSTM-DBN的预测算法在水轮机振动故障预测上的有效性。

4 结束语

深度学习神经网络可以处理更复杂的故障信号,能自动从原始信号中提取故障特征,实现智能故障诊断及预测,而无需进行预处理和大量先验知识。在本研究中,以水电机组实际运行数据和历史统计数据相结合,将深度学习神经网络用于智能水轮机故障预测。通过对水轮机故障数据集进行训练分析,将小波包能量带与时频域指标信息结合作为故障特征,运用基于深度学习LSTM-DBN的水轮

机系统振动故障预测方法,实现水轮机振动故障的预测。通过对图表及数据的分析,显示出算法对水轮机振动趋势的预测能力。工程实验验证了该算法的有效性,为水轮机组故障预测与智能化检修维护提供了有效手段。

参 考 文 献

- [1] 王浩天,单甘霖,孙健,等.一种基于INW-ESN的故障融合预测方法[J].振动、测试与诊断,2018,38(1):162-169.
WANG Haotian, SHAN Ganlin, SUN Jian, et al. A prognostic fusion algorithm based on the INW-ESN[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(1):162-169. (in Chinese)
- [2] 刘明华,南海鹏,余向阳.基于模糊神经网络的水轮机调速器故障诊断[J].水力发电学报,2012,31(3):234-239.
LIU Minghua, NAN Haipeng, YU Xiangyang. Fault diagnosis of hydro turbine governor based on fuzzy neural networks [J]. Journal of Hydroelectric Engineering, 2012, 31(3):234-239. (in Chinese)
- [3] 王奉涛,刘晓飞,邓刚,等.基于长短期记忆网络的滚动轴承寿命预测方法[J].振动、测试与诊断,2020,40(2):303-309.
WANG Fengtao, LIU Xiaofei, DENG Gang, et al. Remaining useful life prediction method for rolling bearing based on the long short-term memory network[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(2):303-309. (in Chinese)
- [4] QING Y, LI K, LIANG Z H, et al. Hybrid forecasting model based on long short term memory network and deep learning neural network for wind signal[J]. Applied Energy, 2019, 236:262-272.
- [5] ZHANG C L, HE Y G, DU B L, et al. Transformer fault diagnosis method using IoT based monitoring system and ensemble machine learning[J]. Future Generation Computer Systems, 2020, 108:533-545.
- [6] WEI Q L, NIKOLA K, MARIOS P, et al. Deep learning neural networks: methods, systems, and applications[J]. Neurocomputing, 2020, 396:130-132.
- [7] ZHAO R, YAN R Q, CHEN Z H, et al. Deep learning and its applications to machine health monitoring [J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [8] 池永为,杨世锡,焦卫东.基于LSTM-RNN的滚动轴承故障多标签分类方法[J].振动、测试与诊断,2020,40(3):563-571.
CHI Yongwei, YANG Shixi, JIAO Weidong. A multi-

- label fault classification method for rolling bearing based on LSTM-RNN[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3):563-571. (in Chinese)
- [9] 孟小凡, 宋华. 基于神经网络的卫星姿控系统故障预测[J]. 系统仿真学报, 2019, 31(11):2499-2508.
MENG Xiaofan, SONG Hua. Fault prediction of satellite attitude control system based on neural network[J]. Journal of System Simulation, 2019, 31(11): 2499-2508. (in Chinese)
- [10] 周奇才, 王益飞, 赵炯, 等. 基于 LSTM 循环神经网络的盾构机故障预测系统设计[J]. 现代机械, 2018(5): 35-40.
ZHOU Qicai, WANG Yifei, ZHAO Jiong, et al. Design of fault prediction system for shield machine based on LSTM recurrent neural network[J]. Modern Machinery, 2018(5):35-40. (in Chinese)
- [11] 于洋, 何明, 刘博, 等. 基于 TL-LSTM 的轴承故障声发射信号识别研究[J]. 仪器仪表学报, 2019, 40(5): 51-59.
YU Yang, HE Ming, LIU Bo, et al. Research on acoustic emission signal recognition of bearing fault based on TL-LSTM[J]. Chinese Journal of Scientific Instrument, 2019, 40(5):51-59. (in Chinese)
- [12] 杜小磊, 陈志刚, 许旭, 等. 基于小波卷积自编码器和 LSTM 网络的轴承故障诊断研究[J]. 机电工程, 2019, 36(7):663-668.
DU Xiaolei, CHEN Zhigang, XU Xu, et al. Fault diagnosis of bearing based on wavelet convolutional auto-encoder and LSTM network[J]. Journal of Mechanical & Electrical Engineering, 2019, 36(7):663-668. (in Chinese)
- [13] 程宝清, 韩凤琴, 桂中华. 基于小波的灰色预测理论在水电机组故障预测中的应用[J]. 电网技术, 2005(13): 40-44.
CHENG Baoqing, HAN Fengqin, GUI Zhonghua. Application of wavelet transform based grey theory to fault forecasting of hydroelectric generating sets[J]. Power System Technology, 2005(13):40-44. (in Chinese)
- [14] 何理瑞. 振动诊断在水轮机故障诊断与失效分析中的应用[J]. 浙江水利水电学院学报, 2014, 26(4):78-80.
HE Lirui. Application of vibration diagnosis in turbine fault diagnosis and failure analysis[J]. Journal of Zhejiang University of Water Resources and Electric Power, 2014, 26(4):78-80. (in Chinese)
- [15] XU B, CHEN D, LI H, et al. Priority analysis for risk factors of equipment in a hydraulic turbine generator unit [J]. Journal of Loss Prevention in the Process Industries, 2019, 58:1-7.



第一作者简介:罗毅,男,1969年10月生,博士、教授。主要研究方向为热工控制系统的优化控制、仿真建模、故障诊断与预测以及智能优化算法。曾发表《基于熵权法和灰色关联分析法的输电网规划方案综合决策》(《电网技术》2013年第37卷第1期)等论文。

E-mail:lyphzh@163.com

欢迎订阅《振动、测试与诊断》

《振动、测试与诊断》由工业和信息化部主管,南京航空航天大学 and 全国高校机械工程测试技术研究会联合主办,是反映振动、动态测试及故障诊断学科领域的科研成果及其应用情况的技术性刊物。主要刊登国内外以振动测试与故障诊断为中心的动态测试理论、方法和手段的研究及应用方面的技术文献,包括实验测试技术、测试仪器的研制、方法和系统组成、信号分析、数据处理、参数识别与故障诊断以及有关装置的设计、使用、控制、标定和校准等,不拘泥于行业和测试项目。

本刊为 EI Compendex 数据库收录期刊和中文核心期刊,双月刊,每逢双月末出版,每本定价 30 元,全年 180 元。欢迎订阅和投稿,欢迎在本刊刊登各类广告和科技信息。

编辑部地址:南京市御道街 29 号 邮政编码:210016 电话:(025)84893332

邮发代号:28-239 E-mail:qchen@nuaa.edu.cn 网址:http://zdc.nuaa.edu.cn

(第 42 卷卷终)