

基于灰色神经网络的地铁牵引用电预测模型

张 军¹ 王 凯¹ 刘佳喜¹ 李 根¹ 赵 岩¹ 王 鹏¹
耿 伟¹ 张 浩² 陈 欢²

(1. 天津市地下铁道集团有限公司, 300011, 天津; 2. 天津凯发电气股份有限公司, 300392, 天津)

摘 要 [目的] 为了提高列车运行效率, 需对地铁牵引能耗进行监测, 并建立相关能耗模型对地铁牵引能耗进行预测分析。[方法] 介绍了灰色预测模型和 BP(反向传播)神经网络的基本原理; 以天津某典型地铁车站 2021 年 6 月的牵引日用电量数据为例, 采用灰色关联分析法筛选出与地铁牵引日用电量关联度大的影响因素, 基于 GM(1,1) 灰色预测模型预测出短期牵引日用电量; 将所筛选出的关联度大的影响因素、GM(1,1) 灰色预测模型预测的短期牵引日用电量及相邻历史牵引日用电量数据, 作为 BP 神经网络模型中的输入量进行训练, 建立 GM-BP 灰色神经网络模型, 并生成所需短期地铁牵引日用电量预测数据。[结果及结论] 与传统 GM(1,1) 灰色预测模型和 BP 神经网络模型相比, 通过 GM-BP 灰色神经网络模型预测的短期牵引日用电量预测误差有明显的改善, 能够作为有效的地铁牵引能耗数据进行短期预测数据分析。

关键词 地铁; 牵引日用电量预测; 灰色神经网络

中图分类号 TM714; U239.5

DOI:10.16037/j.1007-869x.2024.07.003

Prediction Model of Metro Traction Power Consumption Based on Grey Neural Network

ZHANG Jun¹, WANG Kai¹, LIU Jiayi¹, LI Gen¹, ZHAO Yan¹, WANG Peng¹, GENG Wei¹, ZHANG Hao², CHEN Huan²

(1. Tianjin Rail Transit Co., Ltd., 300011, Tianjin, China;

2. Tianjin Keyvia Electric Co., Ltd., 300392, Tianjin, China)

Abstract [Objective] In order to improve train operational efficiency, it is necessary to monitor metro traction power consumption and establish a relevant energy consumption model for prediction analysis of metro traction power consumption.

[Method] The basic principles of grey prediction model and BP (backpropagation) neural network are introduced. Taking the traction daily electricity consumption data for a typical metro station in Tianjin in June 2021 as example, the grey correlation analysis method is used to select the influencing factors with high correlation to the daily traction power consumption of

metro. Based on the GM(1,1) grey prediction model, the short-term traction daily power consumption is predicted. The selected influencing factors with high correlation, the short-term traction daily power consumption predicted by GM(1,1) grey model, and the adjacent historical traction daily power consumption data are used as input for training in BP neural network model to establish the GM-BP grey neural network model. The required short-term metro traction daily power consumption prediction data is generated. [Result & Conclusion] Compared with conventional GM(1,1) grey prediction model and BP neural network model, the prediction error of short-term traction daily power consumption predicted by the GM-BP grey neural network model shows significant improvement, and can be used as effective metro traction power consumption data for short-term prediction data analysis.

Key words metro; estimated traction daily power consumption prediction; grey neural network

0 引言

截至 2022 年 3 月, 中国大陆地区共有 51 个城市开通运营城市轨道交通线路 273 条, 运营里程共 8 837 km, 实际开行列车 277 万列次, 完成客运量 16 亿人次。伴随着城市轨道交通的快速发展, 城市轨道交通用电量也急剧增加。城市轨道交通用电量占社会总用电量的 1% ~ 2%, 是城市用电大户, 其中牵引供电系统约占城市轨道交通用电量的 44%。城市轨道交通行业积极响应国家“减碳”目标, 提高能耗利用率, 因此有必要对地铁牵引供电系统进行研究。

随着地铁智慧车站能源管理系统中多数据接入及分析的应用发展, 以及机器学习技术的应用发展, 二者已能对短期地铁牵引用电情况进行深入分析, 提供数据支持和技术支撑, 并在智慧车站平台上建立牵引用电分析预测模块, 提高地铁牵引供电系统的智能化管理水平。

短期地铁牵引用电的预测是牵引用电研究的一个研究热点,通过分析短期地铁牵引用电的情况,挖掘影响牵引用电因素与牵引用电量之间的关系,找出地铁牵引用电的主要影响因素,建立合适的短期地铁牵引用电预测模型,并提前预判地铁牵引用电量。这对地铁运营合理规划,提高地铁运营管理水平,减少地铁牵引能耗,提高有效牵引能耗,具有重要的指导意义。

本文以天津某典型地铁车站 2021 年 6 月的牵引日用电量数据为例(数据由智慧车站能源管理系统提供),结合客运量、发车次数、气候条件等常规用电预测相关数据,借助灰色关联分析,筛选出地铁牵引日用电量的主要影响因素,并通过 GM(1,1) 灰色模型预测牵引日用电量。将筛选出的关联度大的影响因素、GM(1,1) 灰色模型预测的短期牵引日用电量,以及相邻历史牵引日用电量数据,作为 BP(反向传播)神经网络的输入,提出一种 GM-BP 灰色神经网络模型,用于预测地铁车站短期牵引日用电量,并通过仿真试验,验证本文提出的 GM-BP 灰色神经网络模型的有效性。本文研究可为地铁行车图的合理确定提供参考与借鉴。

1 灰色预测模型和 BP 神经网络基本原理

1.1 灰色关联分析

灰色关联分析是一种多因素统计分析方法,是以各种因素的样本数据为依据,通过灰色关联度来描述因素之间的强弱、次序和大小的关系^[1]。灰色关联分析主要是通过确定参考数据列和各种影响因素数据列的几何形状的相似度来判断参考数据列和影响因素列间的关联程度。通过灰色关联分析可以挖掘出对参考数据列影响大的影响因素,减少不相干的因素对数据分析的影响。

在 t 时刻,两个曲线 x_p (第 p 个曲线) 和 x_0 的关联系数 $\xi_{0p}(t)$ 可以表示为:

$$\xi_{0p}(t) = \frac{\Delta_{\min} + \rho\Delta_{\max}}{|x_0(t) - x_p(t)| + \rho\Delta_{\max}} \quad (1)$$

$$\Delta_{\min} = \min_p \min_t |x_0(t) - x_p(t)| \quad (2)$$

$$\Delta_{\max} = \max_p \max_t |x_0(t) - x_p(t)| \quad (3)$$

式中:

ρ ——分辨系数($0 \leq \rho \leq 1$),一般 ρ 取为 0.5;

$x_0(t)$ ——曲线 x_0 在 t 时刻的采样点;

$x_p(t)$ ——曲线 x_p 在 t 时刻的采样点;

Δ_{\min} ——两个曲线 x_p 和 x_0 在 $0, 1, \dots, t$ 时间点内所有数据差值绝对值中的最小值;

Δ_{\max} ——两个曲线 x_p 和 x_0 在 $0, 1, \dots, t$ 时间点内所有数据差值绝对值中的最大值。

关联度 r_{p0} 为关联系数的平均值,可以表示为:

$$r_{p0} = \frac{1}{N} \sum_{q=1}^N \xi_{0p}(q) \quad (4)$$

式中:

r_{p0} ——曲线 x_p 对曲线 x_0 的关联度;

N ——历史关联系数个数。

1.2 灰色预测模型

灰色预测是灰色系统理论中的重要内容,其中应用最为广泛的数学模型是 GM(1,1) 灰色预测模型。GM(1,1) 为一阶数列灰色模型,主要适用于预测时间短、数据资料少、波动不大的系统,可以用于预测本文研究的当月牵引日用电需求。灰色预测模型的详细推理过程参考文献[2]。GM(1,1) 灰色预测模型中,预测值的计算式为:

$$\hat{X}^{(0)}(s+1) = (1 - e^a) \left[X^{(0)}(1) - \frac{u}{a} \right] e^{-as} \quad (5)$$

$$s = 1, 2, \dots, M$$

式中:

$\hat{X}^{(0)}(s+1)$ ——地铁牵引日用电量第 $s+1$ 时刻的预测值;

$X^{(0)}(1)$ ——地铁牵引日用电量第 1 个时刻的实测值;

a ——发展系数,可通过最小二乘法获得;

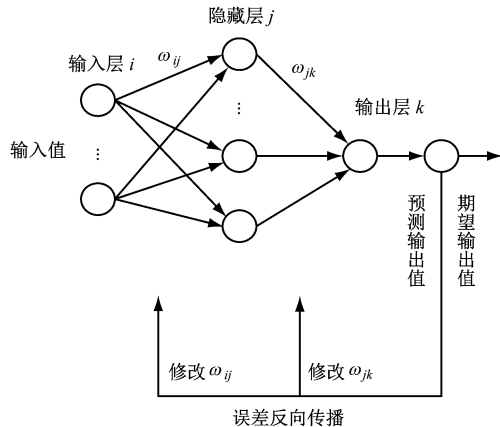
u ——灰色作用量,可通过最小二乘法获得;

M ——数据序列长度。

1.3 BP 神经网络模型

目前在电力系统中,预测用电量常用的人工神经网络是 BP 神经网络^[3]。BP 神经网络属于前馈型网络,一般由三层组成,即输入层、隐含层和输出层,如图 1 所示。其中,隐含层可以包含多个隐含层,且隐含层一般采用 Sigmoid 函数作为激励函数。

通常,将影响电力系统电量的因素作为输入量,将电力系统电量作为输出量,通过现有的大量用电数据对 BP 神经网络进行训练。根据每次训练后的结果计算误差函数,并分别对每层神经元求偏导,修改各神经元的权值。经过多次迭代的权值更新后,可以获得最小误差的 BP 神经网络模型。最后,将所需预测的数据输入 BP 神经网络后可以获得输出值,即为该数据的预测值。



注: ω_{ij} 和 ω_{jk} 为不同神经元之间的权值。

图1 BP神经网络模型示意图

Fig. 1 Diagram of BP neural network model

2 建立 GM-BP 灰色神经网络模型

对地铁牵引日用电量影响因素及其数据进行汇总,删去地铁列车类型、列车编组、牵引方式等不变因素的数据,包括当日是否为节假日、当日最高温度、当日最低温度、当日天气、当日风速、当日进站客运量、当日出站客运量、当日总客运量、当日进出站客运量差值和当日总发车次数。利用灰色关联分析求取各影响因素的关联度。由灰色关联分析理论可知,一般关联度高于 0.7 的影响因素为重要因素,关联度为 0.5~0.7 的影响因素为比较重要因素,其余影响因素为不重要因素。因此,依次筛选出关联度大于 0.5 的影响因素。

采用 GM(1,1) 灰色预测模型预测短时间地铁牵引日用电量。灰色预测模型只需较少的数据量就能对原数据序列进行预测。数据量小是灰色预测模型进行数据预测的一个优势,但其预测结果往往误差较大。然而,灰色预测模型的预测结果虽然误差较大,但仍可以从整体上预测数据序列的走势。此外,由于地铁牵引日用电量分布不均衡,一般与近期用电量相类似,其近期日用电量也能够从侧面反映出地铁牵引日用电量的变化趋势。

将关联度大于 0.5 的影响因素、GM(1,1) 灰色预测模型预测的短时间地铁牵引日用电量,以及相邻 3 d 地铁牵引日用电量作为 BP 神经网络的输入,建立 GM-BP 灰色神经网络模型。采用这三类数据作为输入,能够将 GM(1,1) 灰色预测模型和 BP 神经网络模型各自的优势发挥出来,提升地铁牵引日用电量预测的准确性。

3 试验结果与分析

3.1 地铁牵引日用电量影响因素灰色关联分析

对 2021 年 6 月 30 日某地铁站的牵引日用电量进行统计,经过灰色关系系数分析后可以获得各因素的关联度结果。其中,与地铁牵引日用电量关联度大于 0.5 的数据项及其排名如表 1 所示。由表 1 可知:牵引日用电量与当日总发车次数、当日总客运量、当日最低温度、当日最高温度关联度较大,其他因素对牵引日用电量的影响不大。

表 1 与地铁牵引日用电量关联度大于 0.5 的数据项及其排名

Tab. 1 Data items with metro traction daily power consumption correlation over 0.5 and their rankings

数据项	关联度	排名
当日总发车次数	0.773	1
当日总客运量	0.644	2
当日最低温度	0.615	3
当日最高温度	0.555	4

由文献[4]可知:① 地铁列车满载情况下,乘客质量在列车总质量中一般占 25%~30%;而当列车满载率下降至 50% 时,乘客质量在列车总质量中的占比将下降为 17%。随着满载率的下降,牵引能耗主要用于无效牵引。② 随着列车满载率从 100% 逐渐降至 50% 以下,人均单位客运量所消耗的能耗将迅速上升;当列车满载率为 50% 时,人均单位客运量所消耗的能耗将增加 69.8%;当列车满载率低于 40% 时,地铁牵引能耗将成倍增长;当列车满载率为 80%~100% 时,列车有效牵引能耗将位于最优区间。

结合表 1 和文献[4]可知:地铁牵引日用电量和客运量的关联度为 0.644,排在第 2 位,故其影响并不是最大的,这也间接证明了乘客质量对地铁牵引日用电量的影响有限;若列车满载率过低,将会显著增加列车的无效牵引用电;地铁牵引日用电量主要与当日总发车次数相关。


综上所述,在当日总客运量不变的情况下,控制合理发车间隔及增加列车满载率,均能够提高列车的有效牵引用电,减少牵引日用电量。

3.2 GM-BP 灰色神经网络模型分析

GM-BP 灰色神经网络模型由 GM(1,1) 灰色预测模型和 BP 神经网络模型组成。通过灰色关联分

析筛选影响地铁牵引日用电量的因素,并将分析结果中的当日总发车次数、当日总客运量、当日最低温度和当日最高温度作为 BP 神经网络模型的输入量。同时,GM(1,1)灰色预测模型的输出预测数据可以作为 2021 年 6 月份牵引日用电量数据变化趋势的参考依据,并将其作为 BP 神经网络模型的一个输入量。在对整个 6 月份原始牵引日用电数据曲线进行分析时发现,牵引日最大用电量是最小用电量的 1.98 倍,数据平稳性较差,数据间邻近数据更具有参考意义,故本文将邻近 3 d 的牵引数据也作为 BP 神经网络的 3 个输入量。以 6 月 20 日的数据为例,除了分析 6 月 20 日的日期外,还增加了 6 月 17 日、6 月 18 日和 6 月 19 日的数据作为 6 月 20 日 BP 神经网络数据训练的 3 个输入,其他日期依次类推。对于有缺失的训练数据,将当天数据作为缺失数据进行补充。

将所有数据放入 BP 神经网络中进行训练,获得的不同计算模型下,2021 年 6 月某地铁站牵引日用电量预测结果对比如图 2 所示。从整体上来看,GM(1,1)灰色预测模型、BP 神经网络模型与原始牵引用电数据之间的误差均较大,但其误差在允许范围内。GM-BP 灰色神经网络模型预测的数据更接近原始牵引用电数据,预测效果最佳。GM(1,1)



注:3 种计算模型中,6 月 1 日—6 月 25 日的数据为拟合值,6 月 26—6 月 30 日的数据为预测值。

图 2 不同计算模型下的地铁牵引日用电量预测结果对比 (2021 年 6 月)

Fig. 2 Comparison of metro traction daily power consumption prediction results by different calculation models (June 2021)

灰色预测模型仅作为辅助方法,用以判断地铁牵引日用电量的走向趋势,并修正 BP 神经网络的误差。

采用 GM(1,1)灰色预测模型、BP 神经网络模型和 GM-BP 灰色神经网络模型获得的地铁牵引日用电量预测值及其相对误差统计数据,如表 2 所示。采用平均绝对百分比误差 γ_{MAPE} 、均方根误差 γ_{RMSE} 及平均绝对误差 γ_{MAE} 评价指标来验证 3 种模型的准确性,则有:

$$\gamma_{MAPE} = \frac{1}{M} \sum_{i=1}^M \left| \frac{\hat{X}_i - X_i}{X_i} \right| \quad (6)$$

$$\gamma_{RMSE} = \frac{1}{M} \sqrt{\sum_{i=1}^M (\hat{X}_i - X_i)^2} \quad (7)$$

$$\gamma_{MAE} = \frac{1}{M} \sum_{i=1}^M |\hat{X}_i - X_i| \quad (8)$$

式中:

\hat{X}_i ——牵引日电量预测值序列;

X_i ——原始牵引日电量值序列。

将表 2 中 3 个计算模型的统计数据分别按式 (6)~式 (8) 进行计算,求出各模型的 γ_{MAPE} 、 γ_{RMSE} 、 γ_{MAE} 指标值。GM(1,1)灰色预测模型的 γ_{MAPE} 、 γ_{RMSE} 、 γ_{MAE} 分别为 0.110、163、723;BP 神经网络模型的 γ_{MAPE} 、 γ_{RMSE} 、 γ_{MAE} 分别为 0.044、65、282;GM-BP 灰色神经网络模型的 γ_{MAPE} 、 γ_{RMSE} 、 γ_{MAE} 分别为 0.025、39、172。由此可知,GM-BP 灰色神经网络模型的指标最优,BP 神经网络次之,GM(1,1)灰色预测模型最差,这表明将 GM(1,1)灰色预测模型处理后的数据作为 BP 神经网络模型的输入,能够改善 BP 神经网络模型的输出误差。结合图 2 可知,在 6 月 26 日—6 月 30 日中,GM-BP 灰色神经网络模型的预测数据更接近实际结果。

4 结语

在短期牵引日用电预测模型中,相比于传统的 GM(1,1)灰色预测模型和 BP 神经网络模型,采用 GM-BP 灰色神经网络模型能够提高预测数据的预测精度,进而为列车运行图的合理规划提供参考,最终达到提高列车有效牵引能耗、降低牵引用电量的目的。GM-BP 灰色神经网络模型适用于预测短期序列,后续可以根据实际情况,对一整年中的每个月分别建立一个 GM-BP 灰色神经网络模型,预测整年度的牵引日用电量。在此基础上,该模型还能建立综合考虑列车有效牵引能耗和乘客舒适度的行车调度方案,使列车运营朝着智慧化的方向发展。

表 2 采用 3 种计算模型获得的地铁牵引日用电量预测值及其相对误差统计数据

Tab.2 Statistical results of metro traction daily power consumption prediction values and relative errors obtained by three calculation models

日期	原始牵引日用电量/ (kWh)	GM(1,1) 灰色预测模型		BP 神经网络模型		GM-BP 灰色神经网络模型	
		预测值/(kWh)	相对误差/%	预测值/(kWh)	相对误差/%	预测值/(kWh)	相对误差/%
2021-06-01	4 379	4 379	0	4 945	12.9	4 545	3.8
2021-06-02	4 820	5 809	20.5	4 918	2.0	4 678	-3.0
2021-06-03	4 923	5 885	19.6	4 688	-4.8	4 845	-1.6
2021-06-04	6 112	5 962	2.5	5 902	-3.4	6 323	3.5
2021-06-05	6 767	6 039	10.8	7 054	4.2	6 631	-2.0
2021-06-06	6 944	6 116	12.0	6 980	0.5	6 860	-1.2
2021-06-07	6 090	6 194	1.8	6 395	5.0	5 826	-4.3
2021-06-08	6 736	6 271	8.0	6 011	-10.8	6 823	1.3
2021-06-09	6 399	6 349	0.8	6 236	-2.6	6 448	0.8
2021-06-10	7 089	6 426	9.4	7 149	0.9	6 960	-1.8
2021-06-11	5 594	6 504	16.3	5 468	-2.3	5 476	-2.1
2021-06-12	8 066	6 582	18.4	7 670	-4.9	8 364	3.7
2021-06-13	8 408	6 660	20.8	8 213	-2.3	7 920	-5.8
2021-06-14	8 336	6 738	19.2	8 474	1.7	8 547	2.5
2021-06-15	5 136	6 816	32.7	4 679	-8.9	4 986	-2.9
2021-06-16	5 517	6 894	24.9	4 679	-15.2	5 617	1.8
2021-06-17	5 891	6 973	18.4	5 211	-11.5	5 684	-3.5
2021-06-18	6 598	7 051	6.9	6 205	-6.0	6 236	-5.5
2021-06-19	5 850	7 130	21.9	5 811	-0.7	5 833	-0.3
2021-06-20	6 154	7 209	17.1	6 076	-1.3	6 153	0
2021-06-21	7 195	7 288	1.3	7 251	0.8	7 061	-1.9
2021-06-22	8 216	7 367	10.3	7 741	-5.8	8 025	-2.3
2021-06-23	7 518	7 446	0.9	7 691	2.3	7 528	0.1
2021-06-24	7 777	7 525	3.2	7 941	2.1	7 919	1.8
2021-06-25	8 701	7 605	12.6	8 851	1.7	8 689	-0.1
2021-06-26	7 531	7 684	2.1	7 829	4.0	8 070	7.2
2021-06-27	7 176	7 764	8.2	6 818	-5.0	7 393	3.0
2021-06-28	8 188	7 844	-4.2	8 080	-1.3	7 930	-3.2
2021-06-29	8 521	7 924	-7.0	9 153	7.4	8 443	-0.9
2021-06-30	8 066	8 004	-0.8	8 098	0.4	8 373	3.8

参考文献

- [1] 秦拥军, 孟建宇, 谢良甫, 等. 基于灰色关联理论的 Peck 法隧道地表移动参数影响研究[J]. 城市轨道交通研究, 2020, 23(6): 28.
- QIN Yongjun, MENG Jianyu, XIE Liangfu, et al. Surface movement parameters of Peck method tunnel based on gray relational

theory[J]. Urban Mass Transit, 2020, 23(6): 28.

- [2] 张睿兴, 陶彩霞, 谭星. 灰色预测模糊控制在列车自动运行系统中的应用[J]. 城市轨道交通研究, 2014, 17(1): 30.
- ZHANG Ruixing, TAO Caixia, TAN Xing. Application of grey prediction and fuzzy control in ATO system[J]. Urban Mass Transit, 2014, 17(1): 30.

(下转第 26 页)

表 3 所示。由表 3 可知:相比于方法 2 和方法 3,所提出的基于改进 VMD 和 BP 神经网络的温振特征融合齿轮箱轴承故障诊断方法准确率更高,在 3 个数据集上的平均识别准确率均达到了 98% 以上。

表 3 采用不同计算方法时轴承各状态的平均识别准确率

Tab.3 Average identification accuracy rate of each bearing status using different calculation methods

方法	数据集	平均识别准确率/%		
		健康轴承	外圈故障	滚动体故障
方法 1	A	99.10	98.20	98.79
	B	98.70	97.19	98.20
	C	98.60	98.77	97.17
方法 2	A	94.20	88.41	84.04
	B	95.75	86.34	85.92
	C	93.55	85.68	84.27
方法 3	A	92.91	95.83	90.81
	B	93.44	95.29	91.32
	C	94.62	94.27	89.19

4 结语

本文针对高速列车齿轮箱轴承的故障诊断问题,提出一种基于改进 VMD 的轴承振动信号处理与故障特征提取方法,而后将改进的 VMD 与 LLE 特征降维方法和 BP 神经网络结合,建立了温振特征融合的齿轮箱轴承故障诊断模型,并利用高速列车滚动轴承试验台的齿轮箱轴承试验数据对所建立的模型进行了验证。试验结果表明,该模型对齿轮箱轴承故障的平均识别准确率均在 98% 以上,证明了所提方法的有效性和可行性。

参考文献

- [1] 于祥,高世萍,余进. 基于机器学习的动车组齿轮箱轴承故障诊断模型研究[J]. 铁道技术标准(中英文), 2021, 3(9):19.

(上接第 20 页)

- [3] 王宇,刘若晨,李广军. 基于改进遗传算法的神经网络转向架轴承故障诊断[J]. 城市轨道交通研究, 2020, 23(12): 46.
WANG Yu, LIU Ruochen, LI Guangjun. Fault diagnosis of bogie bearing based on neural network optimized by improved genetic algorithm[J]. Urban Mass Transit, 2020, 23(12): 46.
- [4] 张燕燕. 城市轨道交通系统牵引及车站能耗研究[D]. 北京: 北京交通大学, 2009.
ZHANG Yanyan. Study on the power consumption of traction and station of urban rail transit[D]. Beijing: Beijing Jiaotong University, 2009.

YU Xiang, GAO Shiping, YU Jin. Research on machine learning based fault diagnosis modeling of gearbox bearings in high-speed trains[J]. Railway Technical Standard (Chinese & English), 2021, 3(9): 19.

- [2] 方绵绵. 基于变分模态分解的风电齿轮箱轴承故障诊断方法[J]. 工程与试验, 2021, 61(1): 4.
FANG Mianmian. Fault diagnosis method for wind turbine gearbox bearing based on variational mode decomposition[J]. Engineering & Test, 2021, 61(1): 4.
- [3] 陈剑,黄凯旋,吕伍伴,等. 基于 VMD 和卷积神经网络的变工况轴承故障诊断方法[J]. 计量学报, 2021, 42(7): 892.
CHEN Jian, HUANG Kaixuan, LYU Wuyang, et al. Bearing fault diagnosis method based on VMD and convolutional neural network under varying operation conditions[J]. Acta Metrologica Sinica, 2021, 42(7): 892.
- [4] 许子非,缪维跑,李春,等. 基于变分模态分解与卷积神经网络的轴承故障诊断[J]. 热能动力工程, 2021, 36(3): 55.
XU Zifei, MIAO Weipao, LI Chun, et al. Fault diagnosis of bearings based on variational mode decomposition and convolutional neural network[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(3): 55.
- [5] 石坤举. 基于 LLE 算法的转子系统故障特征数据集降维方法研究[D]. 兰州: 兰州理工大学, 2013.
SHI Kunju. The research on LLE data set dimensionality reduction method in rotor system failure[D]. Lanzhou: Lanzhou University of Technology, 2013.
- [6] 陈良,贾春鹏,杨安元. 基于小波-BP 神经网络的发动机轴承故障诊断[J]. 中国新技术新产品, 2018(2): 1.
CHEN Liang, JIA Chunpeng, YANG Anyuan. Fault diagnosis of engine bearing based on wavelet-BP neural network[J]. New Technology & New Products of China, 2018(2): 1.

· 收稿日期:2022-01-07 修回日期:2022-05-31 出版日期:2024-07-10
Received:2022-01-07 Revised:2022-05-31 Published:2024-07-10

· 第一作者:王连富,工程师,1105972517@qq.com
通信作者:王梓帆,硕士研究生,1209315092@qq.com

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

sity, 2009.

· 收稿日期:2022-05-23 修回日期:2022-06-15 出版日期:2024-07-10
Received:2022-05-23 Revised:2022-06-15 Published:2024-07-10

· 第一作者:张军,高级工程师,417903262@qq.com
通信作者:陈欢,高级工程师,804688467@qq.com

· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license