

# 城市轨道交通牵引变电所开关柜运行状态量预测与故障推断

汪理<sup>1</sup> 张亦然<sup>1</sup> 宋大治<sup>1</sup> 苏许俊<sup>2</sup> 邹大云<sup>3</sup> 白思宁<sup>4</sup>

(1. 南京地铁建设有限责任公司, 210012, 南京; 2. 中铁电气化勘测设计研究院有限公司, 300250, 天津; 3. 南京南瑞继保电气有限公司, 211102, 南京; 4. 国网辽宁省电力有限公司沈阳供电公司, 110003, 沈阳//第一作者, 高级工程师)

**摘要** 城市轨道交通牵引变电所开关柜故障直接关系供电系统运行安全,一旦发生故障,会直接影响城市轨道交通系统的安全稳定运行,严重情况下甚至会引发重大安全事故。为科学指导开关柜维护,有效降低运行风险,需要准确预测开关柜运行状态变化趋势并实现故障推断。提出一种基于长短期记忆神经网络的方法来预测开关柜各状态量变化趋势,并借助鲸鱼优化算法对长短期记忆神经网络模型进行参数优化,采用灰色关联分析的方法对牵引变电所开关柜状态量预测值和故障进行关联度分析。基于南方某城市轨道交通牵引变电所开关柜的历史运营数据,利用模型进行预测分析,并将预测信息提供给运维人员,指导开关柜维修决策。结果表明,提出的基于鲸鱼优化算法-长短期记忆神经网络的方法能够准确预判开关柜故障,为城市轨道交通牵引供电设备运行提供可靠保障。

**关键词** 城市轨道交通; 牵引变电所; 开关柜状态量预测; 故障推断; 长短期记忆神经网络模型

**中图分类号** U231.8

**DOI:**10.16037/j.1007-869x.2023.06.023

## Operation State Quantity Prediction and Fault Inference of Urban Rail Transit Traction Substation Switchgear

WANG Li, ZHANG Yiran, SONG Dazhi, SU Xu-jun, ZOU Dayun, BAI Sining

**Abstract** Faults of urban rail transit traction substation switchgear directly affect the security and steady operation of power supply system, also the safe and stable operation of urban rail transit system in case of fault, and even lead to major safety accidents in serious cases. Therefore, accurately predicting the change trend of switchgear operation state and realizing fault inference can scientifically guide the maintenance of switchgear and effectively reduce operation risks. A method based on LSTM (long short-term memory) to predict the change trend of each switchgear state quantity is proposed, and WOA (whale optimization algorithm) is adopted to optimize

LSTM model parameters. Grey Relation Analysis method is used to analyze the correlation degree between the predicted value of the traction substation switchgear state quantity and the fault. Based on the historical operation data of the switchgear in a southern city urban rail transit traction substation, the model is used for predictive analysis, and the information is provided to the operation-maintenance personnel to guide the maintenance decision of the switchgear. The results show that the proposed method based on WOA-LSTM can accurately predict the switchgear faults and provide reliable guarantee for the operation of urban rail transit traction power supply equipment.

**Key words** urban rail transit; traction substation; switchgear state quantity prediction; fault inference; LSTM neural network model

**First-author's address** Nanjing Metro Construction Co., Ltd., 210012, Nanjing, China

开关柜作为城市轨道交通(以下简称“城轨”)牵引变电所的重要设备,发挥着开合线路、控制设备和保护系统的作用<sup>[1]</sup>。然而,在实际运行中,开关柜绝缘异常、触头温度过高等故障都会对城轨牵引供电系统造成极大的安全隐患,甚至威胁城轨运营安全,因此开关柜的状态量预测及故障推断显得尤为重要。

文献[2-4]均采用BP(反向传播)神经网络对开关柜的状态量进行预测。然而,在文献[2]中,BP神经网络初始值采用人工设定,缺点是迭代时间长、易陷入局部最优解。文献[3]利用粒子群算法对BP神经网络初始权值和阈值进行参数寻优,但易陷入局部最优解中并难以得到精确的最优解。文献[4]采用Nadam优化算法对BP神经网络进行参数优化,但未对开关柜故障进行深入研究。文献[5]通过搭建多层卷积神经网络,对不同缺陷类型的故障概率进行预测,不足之处在于池化层丢失

大量有用信息,导致预测精度下降。

目前,关于城轨牵引变电所开关柜状态变化趋势预测和故障推断方法还鲜有报道。本文提出基于鲸鱼优化算法的 WOA-LSTM (鲸鱼优化算法-长短期记忆) 神经网络模型对城轨牵引变电所开关柜状态进行预测。在此基础上,运用灰色关联分析判断状态量和故障之间的关联度,从而推断开关柜故障。

### 1 城轨牵引变电所开关柜运行状态量

城轨牵引变电所开关柜故障是由其运行状态量决定的,主要涉及电气性能和机械性能等 14 个主要状态量。结合文献[6-7]以及现场实际运行状态给出开关柜运行状态量阈值范围,如表 1 所示。

表 1 开关柜运行状态量阈值范围

Tab.1 Threshold range of switchgear operation state quantity

状态量	阈值范围
TEV 瞬时值/V	20 ~ 37
超声波瞬时值/dB	2 ~ 8
气压表压力/0.1 MPa	1.35 ~ 1.45
气压表温度/℃	37 ~ 40
SF <sub>6</sub> 密度/(kg/m <sup>3</sup> )	0.10 ~ 0.14
分合闸线圈电流/A	2.0 ~ 2.5
分合闸时间/ms	50 ~ 110
开关室温度/℃	24 ~ 35
开关室湿度/%	85 ~ 89
绝缘电阻/MΩ	300 ~ 500
电缆接头连接处温度/℃	50 ~ 60
电缆接头温度/℃	50 ~ 60
电缆室内湿度/%	35 ~ 85
负荷率/%	45 ~ 120

注:TEV 为暂态对地电压;SF<sub>6</sub> 为六氟化硫。

表 1 中:TEV 瞬时值和超声波瞬时值主要是局部放电程度的度量指标;SF<sub>6</sub> 气体的压力、密度和温度与开关柜的灭弧和绝缘能力密切相关;分合闸线圈电流和分合闸时间主要是监测开关柜的机械性能指标;开关室温、湿度过大会引起开柜的绝缘性能下降;绝缘电阻对绝缘性能起着重要作用;电缆接头连接处温度、电缆接头温度及室内湿度代表母线和电缆的运行状态;开关柜长期过负荷会引起柜体发热,导致绝缘性能下降。


为了从开关柜状态量监测数据中提取精准、有

效的关键信息,本文采用 WOA-LSTM 神经网络预测开关柜状态量变化趋势,不仅可以降低数据处理的复杂度,还能提高模型的精度。

### 2 基于 WOA-LSTM 神经网络的开关柜故障推断

#### 2.1 WOA-LSTM 神经网络基本原理

LSTM 神经网络是一种改良的神经网络,在预测时间序列方面具有较好的性能<sup>[8-9]</sup>。相比于 RNN (递归神经网络),LSTM 神经网络通过在网络中添加 1 个遗忘门来选择存储或删除信息,从而提升利用信息的有效性。LSTM 神经网络也被广泛应用在语音识别、天气预报及金融股票预测等各种时间序列场景<sup>[10-12]</sup>。LSTM 神经网络细胞结构主要包括遗忘门、输入门和输出门,如图 1 所示。



注: $h$  为网络输出的值; $C_{t-1}$  为上一个细胞结构单元状态的输入; $f_t$  为遗忘门输出; $i_t$  为输入门输出; $C_t$  为当前细胞单元状态的输出; $h_{t-1}$  为上一个时刻的输入; $x_t$  为当前的数据输入; $h_t$  为最终输出; $\sigma$  为 sigmoid 函数; $t$  为时间序列。

图 1 LSTM 细胞结构图

Fig.1 Cellular structure diagram of LSTM

LSTM 神经网络特殊之处在于细胞状态和门结构。如图 1 所示,遗忘门可以有选择性地让信息通过,sigmoid 层承担对  $C_{t-1}$  信息选择全部保留或完全舍弃的任务,如式(1)和式(2)所示。

$$f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \tag{1}$$

$$i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \tag{2}$$

式中:

$W_f, W_i$ ——分别为遗忘门和输入门权重系数矩阵;

$b_f, b_i$ ——分别为遗忘门和输入门偏置项。

输入门的 sigmoid 函数决定更新信息,并由  $\tan h$  函数创建新的候选向量,结合二者状态进行旧细胞状态的更新,如式(3)和式(4)所示。

$$C_{t,0} = \tan h(W_C(h_{t-1}, x_t) + b_C) \quad (3)$$

$$C_t = C_{t-1}f_t + C_{t,0}i_t \quad (4)$$

式中:

$C_{t,0}$ ——单元状态输出;

$W_C$ ——输入单元权重系数矩阵;

$b_C$ ——输入单元偏置矩阵。

输出门决定输出的信息,同样是由 sigmoid 函数确定输出信息,并把细胞状态采用  $\tan h$  函数转换为  $-1$  到  $1$  之间的值,将该值乘以 sigmoid 函数的输出,计算式如式(5)和式(6)所示。

$$o_t = \sigma(W_o(h_{t-1}, x_t) + b_o) \quad (5)$$

$$h_t = o_t \tan(h(C_t)) \quad (6)$$


式中:

$o_t$ ——输出门数值;

$W_o$ ——输出门权重系数矩阵;

$b_o$ ——输出门偏置矩阵。

LSTM 神经网络结构如图 2 所示。每个细胞单元均由圆圈表示,“○”与“-”分别表示 3 个门的打开与关闭,3 个门的协作使 LSTM 神经网络可以储存长期信息。



注:●和○分别表示迭代从此处和从不从此处经过。

图 2 LSTM 神经网络结构图

Fig. 2 Neural network structure diagram of LSTM

## 2.2 基于 WOA 的 LSTM 参数优化

WOA 是一种全新的元启发式优化算法<sup>[13]</sup>,已在机器学习模型参数优化领域得到广泛应用<sup>[14-16]</sup>。因此,WOA 可被用于 LSTM 的参数初始化寻优。

WOA 是在收缩包围机制和螺旋更新位置各有 50% 的几率进行选择,以便在优化过程中更新自身位置,具体过程如下:

$$X_0(t+1) =$$

$$\begin{cases} X_0(t) - AD, & p < 0.5 \\ D e^{bl} \cos(2\pi l) + X_0(t), & p \geq 0.5 \end{cases} \quad (7)$$

式中:

$A$ ——系数向量;

$D$ ——猎物与鲸鱼之间的距离;

$X$ ——当前解的位置向量;

$X_0$ ——当前最优候选解的位置向量;

$b$ ——常数;

$l$ —— $[-1, 1]$  内的随机数;

$p$ —— $[0, 1]$  内的随机数;

$e$ ——均方根误差。

LSTM 的初始参数设定直接决定着开关柜状态量的预测性能,因此本文采用 WOA 对 LSTM 神经网络初始参数进行寻优。将鲸鱼个体当作每种优化策略,把鲸鱼的维数当作 LSTM 优化参数的个数,通过不断更新鲸鱼个体自身位置的过程来获取 LSTM 的最优参数组合。最优参数组合包含 3 个参数,分别为隐藏层神经元个数、学习率及迭代次数。隐藏层神经元个数代表神经网络的训练能力,若设置过少会导致开关柜状态量预测性能变差,过多则会增加网络复杂性,导致陷入局部最小值;学习率代表了随着时间的推移,神经网络积累信息的速度;迭代次数代表学习的次数,每次迭代后需更新神经网络参数。选取  $e$  的倒数作为目标函数  $f$ ,定义如下:

$$f = 1 / \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{i,p} - y_{i,0})^2} \quad (8)$$

式中:

$n$ ——样本数量;

$y_{i,p}$ ——开关柜状态量预测值;

$y_{i,0}$ ——开关柜状态量实际值。

$f$  的最优解作为迭代过程中  $e$  的最小值,代表着此时对应模型的预测性能最佳。由此,确定 LSTM 神经网络模型的隐藏层神经元个数、学习率及迭代次数,进而建立基于 WOA-LSTM 神经网络的城轨牵引变电所开关柜状态量预测模型。

## 2.3 灰色关联分析

根据开关柜运行状态量及故障的历史数据,利用灰色关联分析方法,确定状态量与故障之间的关联度<sup>[17-18]</sup>,实现对开关柜故障的推断。

具体地,将开关柜 14 种状态量作为比较序列  $x_i$  ( $i$  为状态量种类,  $i \in [1, 14]$ ),将开关柜故障作为参考序列  $y_j$  ( $j$  为故障类别,  $j \in [1, 5]$ ),每种故障对应不同的状态量关联度。关联度  $r_i$  的计算式如下:

$$\Delta_i(k) = |y_j(k) - x_i(k)| \quad (9)$$

$$\xi_i(k) = (\min_{i,k}(\Delta_i(k)) + \rho \max_{i,k}(\Delta_i(k))) / (\Delta_i(k) - \rho \max_{i,k}(\Delta_i(k))) \quad (10)$$

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k) \tag{11}$$

式中:

- $\Delta_i$ —— $x_i$  和  $y_i$  差值的绝对值;
- $k$ ——不同时间序列的状态量采样值;
- $\xi_i$ ——二者关联系数;
- $\rho$ ——分辨系数, $\rho \in (0,1)$ 。

根据  $r_i$  对每个状态量进行排序,由此获得状态量与故障之间的关联关系。以 SF<sub>6</sub> 断路器故障为例,列举二者的关联度,如表 2 所示。

表 2 SF<sub>6</sub> 断路器故障关联度排序

Tab.2 Ranking of correlation with SF<sub>6</sub> circuit breaker failure

状态量	关联度	状态量	关联度
气压表压力	0.901	电缆室内湿度	<0.1
SF <sub>6</sub> 密度	0.832	分合闸线圈电流	<0.1
超声波瞬时值	0.771	分合闸时间	<0.1
TEV 瞬时值	0.756	绝缘电阻	<0.1
气压表温度	0.465	电缆接头连接处温度	<0.1
开关室湿度	<0.1	负荷率	<0.1
电缆接头温度	<0.1	开关室温度	<0.1

2.4 开关柜故障推断步骤

基于 WOA-LSTM 神经网络和灰色关联分析的开关柜故障推断方法的具体步骤如下:

步骤 1:根据采集到的开关柜历史数据,选取能够表征开关柜运行状态的 14 种状态量,并利用高斯法<sup>[19]</sup>对 14 种状态量进行数据预处理。

步骤 2:将状态量作为输入值  $x_i$  代入式(1)一式(6),采用 WOA 对 LSTM 进行参数寻优,获得最优参数组合后进行训练,得到  $h_i$ 。

步骤 3:采用灰色关联分析方法,通过比较  $h_i$  和故障之间的关联度大小,判断开关柜可能会发生的故障,实现开关柜故障推断。

3 算例分析

3.1 数据预处理

本文选取南方某城轨公司牵引变电所开关柜在线监测系统收集到的历史数据,时间范围为 2020 年 8 月 1 日—2021 年 8 月 1 日,采样间隔为 12 h,共收集 731 组数据。开关柜状态量选取如表 1 所示。采用前 9 个月数据作为训练集,后 3 个月数据作为测试集。

3.2 预测精度指标

为了评价本文提出的 WOA-LSTM 神经网络模型的全局预测精度,选用平均百分比相对误差评价模型预测精度  $P_{MAE}$ 。 $P_{MAE}$  越小,说明模型预测精度越高。 $P_{MAE}$  定义见式(12)。

$$P_{MAE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_{i,p} - y_i}{y_i} \right| \tag{12}$$

3.3 预测结果分析

3.3.1 基于 WOA-LSTM 神经网络模型的预测

由于本文选取的开关柜状态量较多,此处仅详细阐述开关柜气压表压力的预测情况。根据本文第 2.2 节得出 LSTM 最优参数组合:隐藏层神经元个数为 95 个,学习率为 0.008 8,迭代次数为 284。

开关柜气压表压力预测结果如图 3 所示。其余开关柜状态量预测精度如表 3 所示。由图 3 和表 3 可见:模型对状态量的拟合效果较好,证明 WOA-LSTM 神经网络模型具有良好的预测效果。




图 3 SF<sub>6</sub> 气压表压力预测值与实际值对比  
(WOA-LSTM 神经网络模型)

Fig.3 Comparison of predicted and actual pressure of SF<sub>6</sub> barometer (WOA-LSTM neural network model)

表 3 其余 13 种 SF<sub>6</sub> 开关柜状态量的  $P_{MAE}$

Tab.3  $P_{MAE}$  of the other 13 SF<sub>6</sub> switchgear state quantities

状态量	$P_{MAE}/\%$	状态量	$P_{MAE}/\%$
气压表温度	3.94	电缆室内湿度	2.68
SF <sub>6</sub> 密度	1.76	分合闸线圈电流	3.52
TEV 瞬时值	3.61	分合闸时间	2.64
超声波瞬时值	2.42	绝缘电阻	1.96
开关室温度	3.86	电缆接头连接处温度	3.12
开关室湿度	3.92	负荷率	2.47
电缆接头温度	3.74		

3.3.2 各神经网络模型预测性能对比分析

为了验证 WOA-LSTM 神经网络模型的训练性能和  $P_{MAE}$ , 本文将 WOA-LSTM 与 LSTM、PSO(改进粒子群)-LSTM 进行对比分析。选取迭代次数为 100 次,迭代误差如图 4 所示。 $P_{MAE}$  与训练时长如

表4所示。




图4 开关柜迭代误差-迭代次数关系曲线

Fig.4 Relation curve of switchgear iteration error and iteration times

表4 开关柜  $P_{MAE}$  和训练时长对比

Tab.4 Comparison of switchgear $P_{MAE}$ and training time		
方法	$P_{MAE}/\%$	训练时长/s
LSTM	15.46	1 241
PSO-LSTM	8.23	783
WOA-LSTM	2.11	425

由表4可知,相比 LSTM、PSO-LSTM, WOA-LSTM 的  $P_{MAE}$  分别提高 13.35%、7.23%,训练时长分别缩减 66.59%、45.72%。由此可见,本文构建的 WOA-LSTM 预测性能更好。

3.4 开关柜故障推断

通过已有运行数据逐步预测开关柜故障, WOA-LSTM 神经网络模型预估在第565个节点处4个状态量均超出各自阈值,第565个节点对应的时间为2021年5月10日。根据本文第2.4节提出的灰色关联分析方法将状态量与故障进行关联分析,推断 SF<sub>6</sub> 断路器发生故障。根据现场人员反馈,2021年5月10日早晨发生 SF<sub>6</sub> 断路器故障。开关柜故障预测结果与实际情况对比如表5所示。

表5 开关柜故障预测结果与实际情况对比

Fig.5 Comparison of switchgear fault prediction results and actual situation		
日期	预测情况	实际情况
2021-06-15	SF <sub>6</sub> 断路器故障	SF <sub>6</sub> 断路器故障
2021-06-22	正常运行	正常运行
2021-07-02	电缆故障	电缆故障
2021-07-19	超负荷运转	超负荷运转
2021-08-13	正常运行	正常运行
2021-09-08	正常运行	正常运行

4 结论

本文将 WOA 和 LSTM 相结合,对 LSTM 相关参数进行优化,对比传统算法消除了人工调节参数,降低了 LSTM 的随机性。采用灰色关联分析的方法对开关柜状态量预测值和故障进行关联性分析,实现了对城轨牵引变电所开关柜故障的准确推断。相较于 LSTM 和 PSO-LSTM, WOA-LSTM 显著提升了预测性能。

参考文献

[1] 周念成,周川,王强钢,等. 基于改进拉普拉斯分值的开关柜故障特征选择和诊断方法[J]. 电网技术, 2015, 39(3): 850.

ZHOU Niancheng, ZHOU Chuan, WANG Qianggang, et al. Improved Laplacian score based fault feature selection of switchgear cabinet and its diagnosis[J]. Power System Technology, 2015, 39(3): 850.

[2] 李少飞,马兴明,杜璇. 基于 ANSYS 和 BPNN 的开关柜温度场及温度预测研究[J]. 黑龙江电力, 2021, 43(1): 53.

LI Shaofei, MA Xingming, DU Xuan. Research on temperature field and temperature prediction of switchgear based on ANSYS and BPNN[J]. Heilongjiang Electric Power, 2021, 43(1): 53.

[3] 郭文强,董瑶,李清华,等. PSO-BP 神经网络在开关柜设备温度预测中的应用[J]. 陕西科技大学学报, 2020, 38(1): 149.

GUO Wenqiang, DONG Yao, LI Qinghua, et al. Application of PSO-BP neural network in temperature prediction for switchgear equipment[J]. Journal of Shaanxi University of Science & Technology, 2020, 38(1): 149.

[4] 文昌斌,石强,郑凯新,等. 基于 EMD-BP 模型的 10 kV 开关柜温度预测[J]. 通信电源技术, 2020, 37(1): 73.

WEN Changbin, SHI Qiang, ZHENG Kaixin, et al. Temperature prediction of 10 kV switchgear based on EMD-BP model[J]. Telecom Power Technology, 2020, 37(1): 73.

[5] 黄雪薇,张宇,马书恒,等. 基于卷积神经网络的开关柜故障率预测方法[J]. 电工技术, 2020(5): 21.

HUANG Xueyou, ZHANG Yu, MA Shuheng, et al. Fault rate prediction method of switchgear based on convolutional neural network[J]. Electric Engineering, 2020(5): 21.

[6] 国家电网公司运维检修部. 电网设备状态检测技术应用典型案例: 2011—2013 年[M]. 北京: 中国电力出版社, 2014.

State Grid Corporation of China, Operations and Maintenance Department. Typical application cases of condition detection technology for power grid equipment: 2011—2013 [M]. Beijing: China Electric Power Press, 2014.

[7] 亢超群,李二霞,盛万兴,等. 基于多源信息融合的配电真空开关柜动态状态评价研究[J]. 高压电器, 2017, 53

- (3): 235.
- KANG Chaoqun, LI Erxia, SHENG Wanxing, et al. Dynamic condition assessment for distribution vacuum switch cabinets based on multi-source information fusion[J]. High Voltage Apparatus, 2017, 53(3): 235.
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735.
- [9] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks[C]// IEEE. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. New York: IEEE, 2013: 6645.
- [10] SUNDERMEYER M, SCHLÜTER R, NEY H. LSTM neural networks for language modeling [J]. INTERSPEECH, 2012, 1: 194.
- [11] 王田. 基于 LSTM 神经网络的我国多气象要素的多模式集成预报研究[D]. 南京: 南京信息工程大学, 2020.
- WANG Tian. Research on multi-model integrated forecast of multi-meteorological elements in China based on LSTM neural network[D]. Nanjing: Nanjing University of Information Science & Technology, 2020.
- [12] 杨青, 王晨蔚. 基于深度学习 LSTM 神经网络的全球股票指数预测研究[J]. 统计研究, 2019, 36(3): 65.
- YANG Qing, WANG Chenwei. A study on forecast of global stock indices based on deep LSTM neural network[J]. Statistical Research, 2019, 36(3): 65.
- [13] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51.
- [14] 赵春华, 胡恒星, 陈保家, 等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J]. 振动与冲击, 2019, 38(10): 31.
- ZHAO Chunhua, HU Hengxing, CHEN Baojia, et al. Bearing fault diagnosis based on the deep learning feature extraction and WOA SVM state recognition[J]. Journal of Vibration and Shock, 2019, 38(10): 31.
- [15] 王珂珂, 牛东晓, 甄皓, 等. 基于 WOA-ELM 模型的中国碳排放预测研究[J]. 生态经济, 2020, 36(8): 20.
- WANG Keke, NIU Dongxiao, ZHEN Hao, et al. Forecast of carbon emissions in China based on WOA-ELM model[J]. Ecological Economy, 2020, 36(8): 20.
- [16] 徐慧, 付迎春, 付朝川, 等. 改进 WOA 算法优化 SVM 的网络入侵检测[J]. 实验室研究与探索, 2019, 38(8): 128.
- XU Hui, FU Yingchun, FU Chaochuan, et al. Improved whale optimization algorithm to optimize support vector machine for network intrusion detection[J]. Research and Exploration in Laboratory, 2019, 38(8): 128.
- [17] 张义涛, 王泽忠, 刘丽平, 等. 基于灰色关联分析和改进神经网络的 10 kV 配电网线损预测[J]. 电网技术, 2019, 43(4): 1404.
- ZHANG Yitao, WANG Zezhong, LIU Liping, et al. A 10 kV distribution network line loss prediction method based on grey correlation analysis and improved artificial neural network[J]. Power System Technology, 2019, 43(4): 1404.
- [18] 韩学森, 刘博文, 李永杰, 等. 基于模糊和灰色关联的配电自动化开关柜故障诊断方法[J]. 电力科学与技术学报, 2021, 36(2): 107.
- HAN Xuesen, LIU Bowen, LI Yongjie, et al. A fault diagnosis method for distribution automation switch cabinet based on fuzzy and gray correlation[J]. Journal of Electric Power Science and Technology, 2021, 36(2): 107.
- [19] 雷杰宇, 高仕斌, 韦晓广, 等. 基于股权分配的能源市场 P2P 能量共享交易模型[J]. 中国电机工程学报, 2022, 42(23): 8548.
- LEI Jieyu, GAO Shibin, WEI Xiaoguang, et al. A shareholding-based energy sharing transaction model for energy market among peer-to-peer prosumers[J]. Proceedings of the CSEE, 2022, 42(23): 8548.

(收稿日期: 2022-01-17)

## 4 月份城市轨道交通客运量同比增长 95.8%

2023 年 5 月 5 日, 据交通运输部发布的 2023 年 4 月城市轨道交通运营数据显示, 2023 年 4 月, 31 个省(自治区、直辖市)和新疆生产建设兵团共有 54 个城市开通运营城市轨道交通线路 292 条, 运营里程 9 652.6 km, 实际开行列车 311 万列次, 完成客运量 25.3 亿人次, 进站客流量 15.2 亿人次。

4 月份, 客运量环比减少 0.1 亿人次、降低 0.5%, 同比增加 12.4 亿人次、增长 95.8%, 较 2019 年月均客运量增加 5.4 亿人次、增长 27.3%。4 月份客运强度平均水平为 0.552 万人次/(km·d), 较 2019 年全年客运强度平均水平增长 1.2%。

(摘编自中国交通新闻网)