

基于综合预测模型和蒙特卡洛的电动汽车保有量及负荷预测方法研究*

李楠, 马宏忠

(河海大学 能源与电气学院, 江苏 南京 211100)

摘要: 电动汽车的规模化发展及其充电设施的持续性建设严重威胁电力系统的稳定性,但是目前尚缺简便有效的电动车保有量和负荷预测方法。因此,建立基于综合预测的电动汽车保有量预测模型,应用灰色预测、反向传播(BP)神经网络以及长短时记忆(LSTM)网络3种预测模型对电动汽车保有量进行预测,获得单预测模型的预测结果,并利用熵权法对单预测模型预测结果分配权重,计算得到综合预测结果。建立基于蒙特卡洛算法的电动汽车负荷预测模型,在保有量预测的基础上,模拟电动汽车电池特征参数和用户出行习惯,对电动汽车无序充电行为进行预测,形成电动汽车日负荷曲线。最后,以某市电动汽车保有量及充电负荷数据验证所提模型的有效性。算例分析表明,所提综合预测模型比单预测模型具有更高的预测精度,负荷预测结果表明规模化电动汽车并网将给电力系统带来新的挑战。

关键词: 电动汽车保有量; 综合预测模型; 蒙特卡洛; 负荷预测

中图分类号: TM715 文献标志码: A 文章编号: 1673-6540(2022)12-0074-07

doi: 10.12177/emca.2022.132

Research on Electric Vehicle Ownership and Load Prediction Method Based on Comprehensive Prediction Model and Monte Carlo*

LI Nan, MA Hongzhong

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: The large-scale development of electric vehicle and the continuous construction of charging facilities seriously threaten the stability of the power system. However, there is still a lack of simple and effective methods for electric vehicle ownership and load prediction. Therefore, the prediction model of electric vehicle ownership based on the comprehensive prediction is established. Three prediction models of grey prediction, back propagation (BP) neural network and long-short term memory (LSTM) network are used to predict the electric vehicle ownership, and the prediction results of the single prediction model are obtained. The entropy weight method is used to assign weight to the prediction results of the single prediction model, and the comprehensive prediction results are calculated. The electric vehicle load prediction model based on Monte Carlo algorithm is established. On the basis of ownership prediction, the characteristic parameters of electric vehicle batteries and user travel habits are simulated to predict the disordered charging behavior of electric vehicle and to form the daily load curve of electric vehicle. Finally, the effectiveness of the proposed model is verified by the data of electric vehicle ownership and charging load in a city. The example analysis shows that the proposed comprehensive prediction model has higher prediction accuracy than the single prediction model, and the load prediction results show that the grid connection of large-scale electric vehicle will bring new challenges to the power system.

收稿日期: 2022-07-31; 收到修改稿日期: 2022-09-19

* 基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司宜兴供电分公司项目(B11031204PEL)

作者简介: 李楠(1997—),男,硕士研究生,研究方向为电力系统自动化。

马宏忠(1962—),男,博士,教授,研究方向为电力系统自动化。

Key words: electric vehicle ownership; comprehensive prediction model; Monte Carlo; load prediction

0 引言

随着化石能源的日渐短缺,以电动汽车为代表的新能源汽车成为未来汽车行业发展的方向^[1-2]。由于政策支持和技术推动,电动汽车前景可观,近年来其保有量呈现高增长状态。2014年,我国电动汽车销量仅为 7.4 万辆,而 2018 年,电动汽车销量达到 125.6 万辆,出现 15 倍以上的爆发式增长。近年来因疫情等因素影响,电动汽车市场有所收缩,但仍保持一定增长,2021 年全年电动汽车销量达到 136.7 万辆^[3]。然而,电动汽车大规模接入电网势必加剧电力系统的不稳定性,因此,对电动汽车保有量以及充电负荷预测具有重要意义。

针对电动汽车保有量预测,现有方法大多采用单预测模型。文献[4]建立基于 Bass 模型和 GM(1,1)模型的电动汽车保有量预测模型,对我国 2020~2030 年的电动汽车保有量进行预测。文献[5]利用 Bass 模型和灰色 Lotka-Volterra 模型对电动汽车短期保有量进行预测,并对政府政策扶持方法和电动汽车发展前景提出相关建议。文献[6]采用弹性系数法和千人保有量法建立电动汽车保有量预测模型,对陕西省电动汽车保有量进行预测。上述文献在参数估计的基础上利用单预测模型对电动汽车保有量进行预测,可以根据预测中偏大或偏小的趋势预测变化效果,但随着预测步长的加长,预测误差将逐渐增大。相较于单预测模型,综合预测模型能够结合各单预测模型的优点,并利用权重分配方法,进一步提高预测准确率。目前,综合预测已经广泛应用于其他各个领域。文献[7]建立基于 k-SVD-OMP 和 KELM 组合方法的短期光伏功率预测模型,得到了较好的预测结果和精度。文献[8]提出一种基于极端梯度提升和长短时记忆(LSTM)网络模型的短期光伏出力组合预测模型,对 2018 年光伏电站人工运维大数据进行预测。文献[9]建立非线性状态估计和神经网络组合的预测模型,对风电机组故障情况进行预测。

针对电动汽车负荷预测,现有研究主要集中在负荷时空分布特性。在统计大量交通信息的基础上,形成一条涵盖用户出行目的、出行时间和活

动数量等相关信息的出行链,建立出行链理论,从而完成负荷预测。文献[10]提出一种基于图 WaveNet 的电动汽车充电负荷预测框架,利用耦合电网-交通网内相关信息对充电站充电负荷进行预测。文献[11]提出一种考虑季节特性的多时间尺度电动汽车负荷预测模型,对未来数年电动汽车的发展趋势以及考虑季节特性的多时间尺度电动汽车负荷进行预测。但是上述方法无法考虑空间分布上的随机性和波动性,且缺少准确的未来电动汽车保有量数据,实际应用效果不佳,预测准确率不高。而基于蒙特卡洛的电动汽车负荷预测方法,可以分析用户的出行习惯以及用户的使用习惯,形成起始充电时间和出行时刻等相关数据的概率分布。采用蒙特卡洛算法模拟用户出行,从而对某一地区负荷进行预测,可以有效反映电动汽车空间分布上的随机性以及波动性。

综上所述,本文建立基于综合预测模型和蒙特卡洛的电动汽车保有量以及负荷预测模型。组合灰色预测、反向传播(BP)神经网络和 LSTM 网络模型,并利用熵权法分配 3 种单预测模型预测结果,得到综合预测结果。基于 2022 年电动汽车保有量,采用蒙特卡洛算法,分析电动汽车起始充电时间等用户出行特征,对电动汽车规模化接入电网后的负荷变化进行预测。

1 电动汽车保有量预测模型

预测模型对预测结果具有重要影响,选用合适的预测模型可以有效提高预测精度。时间序列数据具有非周期、非线性以及非平稳等复杂性,为兼顾不同预测模型在预测过程中的优势,本文组合灰色预测、BP 神经网络以及 LSTM 网络 3 种方法对电动汽车保有量进行预测。综合预测模型可以表示为

$$Q = \sum_{i=1}^3 \omega_i(t) y_i(t) \quad (1)$$

式中: $y_i(t)$ 为灰色预测、BP 神经网络以及 LSTM 网络的预测结果; $\omega_i(t)$ 为灰色预测、BP 神经网络以及 LSTM 网络的权重,和为 1。

1.1 单预测模型

电动汽车数据具有线性、周期性以及复杂性等不同特性,灰色预测模型对线性数据具有较强

的适应性, BP 神经网络模型在周期性时间序列数据上效果较好, LSTM 网络模型能够较好地对复杂时间序列数据进行预测。

1.1.1 灰色预测

灰色预测是用来预测灰色系统的预测方法。其通过寻找已知数据的规律,生成有较强规律性的数据序列,建立相应的微分方程模型,从而对未来的发展趋势进行预测,可表示为

$$\hat{y}^{(1)}(t) = \left[y^{(0)}(1) - \frac{\hat{b}}{\hat{a}} \right] e^{-\hat{a}(t-1)} + \frac{\hat{b}}{\hat{a}} \quad (2)$$

1.1.2 BP 神经网络

BP 神经网络根据所给的训练样本输入和输出向量不断学习,并对神经元之间的权值和阈值进行调整,使网络不断逼近样本输入和输出之间的映射关系,再通过测试样本来预测结果的准确性。首先定义输出误差信号:

$$e_j(n) = d_j(n) - y_j(n) \quad (3)$$

式中: $y_j(n)$ 为神经元 j 在 n 步迭代的实际输出值; $d_j(n)$ 为期望输出值。

定义代价函数:

$$\varepsilon(n) = \frac{1}{2} \sum_{j=1}^m e_j^2(n) \quad (4)$$

权值调整公式为

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (5)$$

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (6)$$

式中: η 为学习率参数。

最后输出结果:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (7)$$

$$y_i(n) = \varphi[v_j(n)] \quad (8)$$

式中: $\varphi(x)$ 表示神经元非线性激活函数。

1.1.3 LSTM 网络

LSTM 网络在传统递归神经网络的基础上,增加了具有记忆单元的神经网络层,包括输入门、输出门和遗忘门 3 个模块,增加了对时间序列数据预测的记忆能力,广泛应用于时间序列数据的预测。

输入门负责保存记忆单元中的相关信息,其更新公式为

$$i_t = \text{sigmoid}(a_{ix}x_t + a_{ih}h_{t-1} + a_{ic}C_{t-1} + b_i) \quad (9)$$

式中: sigmoid 为激活函数; a_{ix} 、 a_{ih} 、 a_{ic} 为输入门权

重系数; x_t 为 t 时刻的输入; h_{t-1} 为 $t-1$ 时刻的输出; C_{t-1} 为 $t-1$ 时刻的候选向量; b_i 为输入门偏置。

输出门负责输出记忆单元中的相关信息,只输出算法所需信息,其更新公式为

$$O_t = \text{sigmoid}(a_{ox}x_t + a_{oh}h_{t-1} + a_{oc}C_{t-1} + b_o) \quad (10)$$

式中: sigmoid 为激活函数; a_{ox} 、 a_{oh} 、 a_{oc} 为输入门权重系数; x_t 为 t 时刻的输入; h_{t-1} 为 $t-1$ 时刻的输出; C_{t-1} 为 $t-1$ 时刻的候选向量; b_o 为输出门偏置。

遗忘门负责丢弃记忆单元中的相关信息,其更新公式为

$$f_t = \text{sigmoid}(a_{fx}x_t + a_{fh}h_{t-1} + a_{fc}C_{t-1} + b_f) \quad (11)$$

式中: sigmoid 为激活函数; a_{fx} 、 a_{fh} 、 a_{fc} 遗忘门权重系数; x_t 为 t 时刻的输入; h_{t-1} 为 $t-1$ 时刻的输出; C_{t-1} 为 $t-1$ 时刻的候选向量; b_f 为遗忘门偏置。

1.2 组合权重

不同数据的权重分配组合具有不同类型,主要分为主观赋权和客观赋权。主观赋权往往容易受到人为因素的干扰,预测结果与实际结果存在较大偏差,因此本文采用客观赋权的方法,对单预测模型预测结果进行组合。熵权法在客观赋权方法中应用效果最佳,其利用不同模型预测的保有量数据计算信息熵大小,对不同预测模型所占权重进行分配,可以最大程度地保存有效信息。

对于 m 个对象,将每个传感器采集的 n 维数据进行拼接,构成矩阵 X :

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (12)$$

对 X 进行一次标准化,可以得到 Z ,其中标准化公式为

$$z_{ij} = \frac{x_{ij} - \min\{x_{1j}, x_{2j}, x_{3j}, \cdots, x_{nj}\}}{\max\{x_{1j}, x_{2j}, x_{3j}, \cdots, x_{nj}\} - \min\{x_{1j}, x_{2j}, x_{3j}, \cdots, x_{nj}\}} \quad (13)$$

对 j 个指标而言,信息熵计算公式为

$$e_j = -\frac{1}{\ln n} \sum_{i=1}^n p_{ij} \ln(p_{ij}) \quad (j=1, 2, \cdots, m) \quad (14)$$

其中： $p_{ij} = \frac{z_{ij}}{\sum_{i=1}^n z_{ij}}$ ，且 $\sum_{i=1}^n p_{ij} = 1$ 。

可得各模型熵权为

$$W_j = d_j / \sum_{j=1}^m d_j \tag{15}$$

2 基于蒙特卡洛的电动汽车负荷预测模型

2.1 车辆出行时空模型分析

2.1.1 电动汽车起始充电时间

电动汽车的起始充电时间受到电动汽车的种类、用户个人出行习惯、汽车电池容量、季节以及节假日等多种因素的影响。基于国家统计局数据,本文对北京市交通数据进行调查,得到各类电动汽车起始充电时间的分布情况,如图 1 所示。起始充电时间可以分成 0~12 时和 12~24 时两个时间段。




图 1 电动汽车起始充电时间分布图

本文利用 SPSS 软件拟合电动汽车起始充电时间分布数据得,电动汽车起始充电时间在 0~12 时和 12~24 时两个时间段内符合以下概率密度函数,即符合正态分布,具体拟合参数如表 1 所示:

$$f(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(t-\mu)^2}{2\sigma^2}} \tag{16}$$

式中： σ 为起始充电时间的方差； μ 为起始充电时间的均值。

表 1 起始充电时间拟合参数

车辆类型	私家车		公交车		出租车	
时段/h	0~12	12~24	0~12	12~24	0~12	12~24
数学期望	488.6	1 055.5	528.1	1 081.9	450.1	1 085.5
方差	122.1	167.1	108.3	132.9	82.7	135.7

2.1.2 车辆日行驶里程

私家车的出行里程受到多种因素的影响,其出行主要应用于工作及娱乐。如图 2 所示,本文统计某市私家车日行驶里程,可得工作日与休息日的行驶里程存在明显差别。




图 2 电动汽车日行驶里程分布图

本文利用 SPSS 软件拟合电动汽车日行驶里程,其分布符合以下概率密度函数,即伽马分布:

$$f(x) = \frac{\lambda^\alpha}{\xi(\alpha)} \lambda^{\alpha-1} e^{-\lambda x} \tag{17}$$

式中： $\xi(\alpha)$ 为伽马函数； λ 和 α 分别为尺度和形状参数,其中工作日 $\lambda = 0.045$ 、 $\alpha = 1.6$,节假日 $\lambda = 0.031$ 、 $\alpha = 1.8$ 。

出租车的日行驶里程较为复杂。受到出租车司机的班次选择和城市需求等因素的影响,平均日行驶里程在 300~600 km 之间。本文统计某市出租车日行驶里程,可知出租车日行驶里程可以分成 0~15 时和 15~24 时两个时间段,利用软件对出租车的日行驶里程进行拟合,可知其符合正态分布,其拟合参数如表 2 所示。

表 2 日行驶里程拟合参数

车辆类型	出租车	
时段/h	0~15	15~24
数学期望	335.7	265.4
方差	224.5	225.4

公交车的日行驶里程比较均匀,主要取决于公交车的固定线路长度、发车密度、路阻程度和运营时间等因素。分析调查数据可知,公交车平均行驶里程均在 140~200 km 范围内,并且呈现随机分布的特性,因此本文假设公交车的日行驶里程服从均匀分布[140,200]。

2.2 车辆出行时空模型分析

本文假设整个行驶过程的用电率相同,基于

蒙特卡洛模拟电动汽车的充电负荷模型,对于电动汽车用户的习惯进行仿真,随机抽取包括电动汽车起始充电时间、电动汽车充电功率和电动汽车日行驶里程等参数,算法流程图如图 3 所示。




图 3 电动汽车负荷预测流程图

根据上述数据分析的相关参数,确定仿真的次数、仿真电动汽车的保有量和电动汽车类型所对应的最大行驶里程,完成模拟仿真的程序参数初始化。初始电动汽车荷电状态(SOC)计算式为

$$SOC_1 = \left(SOC_0 - \frac{d}{d_m} \right) \times 100\% \tag{18}$$

式中: SOC_1 为本次充电开始时的电池荷电状态; SOC_0 为上次充电完成时的电池荷电状态; d 为本次行驶的里程; d_m 表示车辆最大行驶里程。

充电所需时间为

$$T = \frac{E}{\eta_i P_i} \tag{19}$$

式中: E 为第 i 类电动汽车的电池容量; η_i 为第 i 类电动车的充电效率; P_i 为第 i 类电动车的充电功率。

各个负荷节点的充电功率为

$$P_{i,k} = \sum_k^N P_{i,t_{k-1},k} \tag{20}$$

式中: $P_{i,k}$ 为第 i 类电动汽车在第 k 个节点的充电

功率之和; $P_{i,t_{k-1},k}$ 为第 i 类电动汽车中满足充电起始时间大于 t_{k-1} 的车辆充电功率。

节点负荷功率叠加为

$$P_k = P_{car,k} + P_{bus,k} + P_{taxi,k} \tag{21}$$

式中: $P_{car,k}$ 、 $P_{bus,k}$ 、 $P_{taxi,k}$ 分别为私家车、公交车和出租车在第 k 个节点的充电功率之和; P_k 表示第 k 个节点的充电功率之和。

3 算法验证

3.1 电动汽车保有量预测

本文以某市电动汽车实际数据为基础,利用构建的综合预测模型预测该市的电动汽车保有量情况,并以此为基础利用蒙特卡洛算法模拟电动汽车充电日负荷情况。

表 3 为 2012~2021 年某市电动汽车保有量数据,以此为基础,利用本文方法进行拟合,并与真实数据对比,验证本文所提模型的有效性。如图 4 所示,本文所提模型对不同类型车辆均具有较高的准确度。

表 3 2012~2021 年某市电动汽车保有量 万辆

年份	总和	私家车	出租车	公交车
2012	1.15	0.93	0.19	0.01
2013	2.85	2.32	0.47	0.03
2014	5.27	4.29	0.88	0.06
2015	8.67	7.07	1.44	0.10
2016	12.18	9.93	2.03	0.14
2017	19.53	15.92	3.26	0.24
2018	27.59	22.50	4.61	0.33
2019	37.70	30.74	6.29	0.45
2020	49.96	40.74	8.34	0.61
2021	64.22	53.37	10.73	0.78




图 4 电动汽车保有量拟合图

为进一步验证本文所提综合预测模型的优越性,与灰色预测、BP 神经网络以及 LSTM 网络 3 种模型对比,如图 5 所示。由图 5 可知,本文所提模型更贴近真实值,综合预测模型、灰色预测模型、BP 神经网络模型以及 LSTM 网络模型的拟合优度分别为 0.98、0.90、0.92 和 0.56,可知本文所提模型具有更高的准确度。




图 5 各预测模型对比图

基于上述的综合预测模型,对 2022~2024 年某市电动汽车保有量进行预测,预测结果如表 4 所示。

表 4 2022~2024 年某市电动汽车保有量 万辆				
年份	总和	私家车	出租车	公交车
2022	81.63	65.30	14.69	1.63
2023	101.67	81.33	18.30	2.03
2024	124.73	99.78	22.45	2.49

3.2 电动汽车日负荷预测

基于 2022 年电动汽车保有量,根据起始充电时间、日行驶里程以及充电功率等出行特性,预测电动汽车工作日的日负荷。如图 6 所示,私家车的充电负荷高峰期主要集中在城市居民下班回家之后的 19~22 时之间。出租车和公交车的充电时间相对来说比较分散,但也存在小的高峰。总负荷在 19~22 时期间较大,可知私家车负荷占很




图 6 电动汽车负荷预测图

大部分。此情况下可以通过价格引导等方式,鼓励用户错峰充电,以缓解用电压力,提高电网利用率。

将电动汽车日负荷曲线与该市电网的负荷曲线叠加,如图 7 所示。电动汽车大规模接入电网后,势必加剧电网的峰谷差,电网的负荷曲线峰谷差越大,对电力系统的安全稳定运行带来的风险越多。因此考虑采用 V2G 技术,负荷低谷时电动汽车充电,负荷高峰时电动汽车放电,以削弱电网峰谷差。




图 7 电动汽车大规模接入电网前后对比图

4 结 语

电动汽车大规模接入电网给电力系统的安全稳定运行带来新的隐患。本文建立基于综合预测模型和蒙特卡洛的电动汽车保有量和负荷预测模型,对某市电动汽车保有量和负荷情况进行预测,得到如下结论。

(1) 针对单预测模型预测精度不高的问题,建立电动汽车保有量综合预测模型,结合灰色预测模型、BP 神经网络模型以及 LSTM 神经网络模型的优势,并利用熵权法组合各预测模型权重,取得了良好的预测结果,预测准确率高达 98%,比单预测模型至少提高了 6%。

(2) 针对现有电动汽车负荷预测方法多集中于时间分布,未考虑空间位置的随机性和波动性的问题,提出基于蒙特卡洛的电动汽车负荷预测方法,分析结果表明电动汽车大规模接入势必加大电网的峰谷差,严重加剧电力系统的不稳定性。

此外,将在后续研究中统计真实的电动汽车实时负荷数据,与本文所提方法的预测结果进行对比,进一步验证本文所提方法的有效性。

【参考文献】

- [1] 邵尹池,穆云飞,余晓丹,等.“车-路-网”模式下电动汽车充电负荷时空预测及其对配电网潮流的影响[J]. 中国电机工程学报, 2017, 37(18): 5207.
- [2] 郭少丹. 电动汽车规模化发展需要充电网支撑[N]. 中国经营报, 2022-07-25(D04).
- [3] 胡玉财,陆张浩,魏家静. 新能源汽车产业规划 2021-2035 解读[J]. 内燃机与配件, 2022(6): 167.
- [4] 楚岩枫,朱天聪. 基于 Bass 模型和 GM(1,1)模型的我国电动汽车保有量预测研究[J]. 数学的实践与认识, 2021, 51(11): 21.
- [5] 张国方,陈行,李顺喜. 基于 Bass 模型和 Lotka-Volterra 模型预测电动汽车保有量[J]. 武汉理工大学学报, 2017, 39(8): 91.
- [6] 王中阳,王威,戴建卓,等. 基于弹性系数法和千人保有量法的陕西省电动汽车保有量的预测[J]. 电网与清洁能源, 2016, 32(5): 142.
- [7] 李军,郑丹阳. 基于 K-SVD-OMP 和 KELM 组合方法的短期光伏功率预测(英文)[J]. Journal of Measurement Science and Instrumentation, 2022, 13(3): 320.
- [8] 谭海旺,杨启亮,邢建春,等. 基于 XGBoost-LSTM 组合模型的光伏出力预测[J/OL]. 太阳能学报, 2022, 43(8): 75.
- [9] 苏连成,邢美玲,张慧. 基于组合预测模型的风电机组关键部位故障检测[J]. 太阳能学报, 2021, 42(10): 220.
- [10] 胡博,张鹏飞,黄恩泽,等. 基于图 WaveNet 的电动汽车充电负荷预测[J/OL]. 电力系统自动化, 2022, 46(16): 207.
- [11] 牛牧童,廖凯,杨健维,等. 考虑季节特性的多时间尺度电动汽车负荷预测模型[J]. 电力系统保护与控制, 2022, 50(5): 74.

~~~~~  
(上接第 46 页)

- [11] 徐洋,刘卫东,高文胜. 用于变压器局部放电检测的套管末屏传感方式的灵敏度研究[J]. 变压器, 2020, 57(6): 49.
- [12] 吴剑,胡耀垓,姜春华,等. 基于卷积神经网络的高压电缆局部放电信号分类[J]. 武汉大学学报(理学版), 2021, 67(3): 232.
- [13] 叶彬,周凯,黄永禄,等. 串联谐振下电缆局部放电的双传感器检测技术[J]. 电网技术, 2021, 45(3): 1188.
- [14] 马星河,张登奎. 基于改进经验小波变换的高压电缆局部放电噪声抑制研究[J]. 电工技术学报, 2021, 36(S1): 353.
- [15] 方静,魏占朋,殷强,等. 220 kV 高压电缆局部放电信号传输特性研究[J]. 电力系统及其自动化学报, 2021, 33(1): 36.
- [16] 徐洋,周电波,丁登伟,等. GIS 盆式绝缘子表面缺陷的局部放电检测[J]. 高压电器, 2020, 56(5): 101.

~~~~~  
(上接第 52 页)

- [10] 杨校林,李菁菁,李易. FINFLO:快速局部异常点检测算法[J]. 数据与计算发展前沿, 2020, 2(6): 82.
- [11] 薛明志,陈商玥,高强. 基于 K-Medoids 聚类算法的低压台区线损异常识别方法[J]. 天津理工大学学报, 2021, 37(1): 26.
- [12] 沈晓钰,王若华,徐颖. 基于电力物联网的台区精益管控模式应用[J]. 集成电路应用, 2020, 37(10): 60.
- [13] 杨翺,孙可,叶刚进,等. 基于聚类技术的“插座式”分布式光伏接入方法及其应用[J]. 浙江电力, 2019, 38(2): 73.
- [14] 钟小强,陈杰,蒋敏敏,等. 基于深度学习的台区线损分析方法[J]. 电网技术, 2020, 44(2): 769.
- [15] 刘东升,代盛国,商学斌,等. 基于压缩感知理论的缺失数据集下线损预测模型[J]. 广东电力, 2019, 32(2): 80.