

DOI:10.3876/j.issn.1000-1980.2023.05.016

基于深度神经网络的直流充电桩远程计量性能检定方法

陈 熙¹,刘秀兰^{1,2},陈慧敏¹,程 林¹,李香龙¹,刘进刚³

(1. 国网北京市电力公司电力科学研究院,北京 100075; 2. 华北电力大学(北京)电气与电子工程学院,北京 102206;
3. 中国电建集团贵阳勘测设计研究院有限公司,贵州 贵阳 550081)

摘要: 为实现对直流充电桩计量性能远程、节约、高效的检定,基于深度神经网络(DNN),采用现场电动汽车直流充电桩充电的大量数据,在对充电过程中各变量与累计电能进行相关性分析的基础上,建立了直流充电桩累计电能计算的 DNN 模型,提出了一种可用于直流充电桩的远程计量性能检定方法。实例验证结果表明:电池荷电状态对累计电能计算的影响最大,电流的影响最小;建立的 DNN 模型可准确计算待测桩的“实际”输出电能,模型计算结果的示值误差与实际检定示值误差间差值的绝对值小于 1%;提出的直流充电桩远程计量性能检定方法可实现高效的直流充电桩计量性能评估。

关键词: 直流充电桩;计量检定;深度神经网络;示值误差;量值传递

中图分类号: TM910.6; TP183 **文献标志码:** A **文章编号:** 1000-1980(2023)05-0119-07

Metering performance evaluation method of DC charging piles based on deep neural networks

CHEN Xi¹, LIU Xiulan^{1,2}, CHEN Huimin¹, CHENG Lin¹, LI Xianglong¹, LIU Jingang³

(1. State Grid Beijing Electric Power Research Institute, Beijing 100075, China;
2. College of Electronics and Electrical Engineering, North China Electric Power University(Beijing), Beijing 102206, China;
3. POWER CHINA Guiyang Engineering Corporation Limited, Guiyang 550081, China)

Abstract: In order to achieve the remote, cost-effective, and efficient evaluation of the metering performance of DC charging piles, a DNN model for calculating accumulated electric energy of DC charging piles is established based on deep neural network (DNN) and a large amount of data of on-site electric vehicles charging on DC charging piles. A method of remote metering performance verification for DC charging piles is proposed, and the correlation between variables and accumulated electric energy during charging is analyzed. The instance verification results show that the state of charge has the greatest influence on the calculation of accumulated electric energy, and the current has the least influence. The established DNN model can accurately calculate the “actual” output energy of the pile to be measured, and the absolute value of the difference between the indication error of model calculation result and the actual verification indication error is less than 1%. Therefore, the proposed method can achieve an efficient metering performance evaluation.

Key words: DC charging piles; metering verification; deep neural network; indication error; value transfer

当前,在“低碳经济”的发展理念下,电动汽车逐渐成为一种流行的交通方式^[1-2],在电动汽车充电桩上产生的充电交易结算规模越来越大^[3]。为避免交易过程中因充电桩计量偏差过大而给用户或者电网经营公司带来直接经济损失,直流充电桩的计量性能需定期逐台进行现场检定^[4-5]。

一般而言,计量器具的检定多采用“量值传递”方法,因此,传统充电桩的检定通常利用标准检定装置作为传递量具,依据相应的检定规程进行充电桩计量性能的现场检定^[6]。但是,充电桩建设数量大、工作空间分布广、运行环境复杂等问题,使得这种方式需要占用大量的人力、物力,极大地提高了运营单位的成本^[7]。近年来,关于交、直流充电桩的检定研究主要是通过优化标准检定装置及检定工序以提高检定效率,如曾博

基金项目: 国网北京市电力公司科技项目(520223230018)

作者简介: 陈熙(1990—),女,工程师,硕士,主要从事电动汽车充电、检测研究。E-mail: xchenaz@163.com

通信作者: 刘进刚(1997—),男,工程师,硕士,主要从事新能源工程、人工智能算法应用研究。E-mail: ljghhu@163.com

引用本文: 陈熙,刘秀兰,陈慧敏,等. 基于深度神经网络的直流充电桩远程计量性能检定方法[J]. 河海大学学报(自然科学版),2023,51(5):119-125.

CHEN Xi, LIU Xiulan, CHEN Huimin, et al. Metering performance evaluation method of DC charging piles based on deep neural networks [J]. Journal of Hohai University(Natural Sciences), 2023, 51(5): 119-125.

等^[8]提出了一种6表位全自动检定系统,提高了直流充电桩的现场检定效率;林勇等^[9]开发了一种车载直流充电桩计量检定平台,可解决现场检定工作中取电难的问题,并提高了现场检定效率。但上述方法仍需去往现场,不能很好地解决检定工作易受天气影响且耗时长等问题。

为克服传统现场检定方法存在的问题,叶佳旻等^[7]提出了计量模块比对和大数据筛选两种新型充电桩检定方法的设想。其中,计量模块对比法需要在充电桩原有内部结构上加装监测用计量模块,可远程、高效地对充电桩计量性能合格与否进行判断,但已投入使用的充电桩需要进行硬件改造从而增加了经费投入。大数据筛选法可依托已建成的物联网、车联网,采集并保存汽车在充电桩上充电过程中产生的大量数据,并采用大数据分析方法来对充电桩的计量性能进行分析评估,更有可能实现低成本、高效率、远距离充电桩的计量检定工作。此外,以大数据作为支撑建立模型以解决复杂问题的深度学习算法^[10-13]已经被用来预测实际生活中的许多复杂难题^[14-15],如电网负荷预测^[16]、变压器故障诊断^[17]等,大数据分析问题的可行性被不断得到证实。

本文在现有研究基础上,以特定电动汽车作为“量值传递”的载体,采用其在直流充电桩上充电产生的大数据和深度学习方法^[18],建立“实际”输出电能计算的深度神经网络模型,进而得出计算结果与直流充电桩示值电能之间的平均相对误差作为充电桩的示值误差,通过相关规程与模型计算示值误差对直流充电桩的计量性能进行检定。

1 直流充电桩远程计量性能检定方法

传统的直流充电桩现场逐台检定工作易受天气、环境等因素影响而效率低下,为克服传统检定工作存在的问题,本文提出了一种远程、高效的直流充电桩计量性能检定方法,该方法的实现流程(图1)如下:将特定电动汽车作为“量值传递”的量具(假设在“量值传递”期内该车的电池状态稳定),利用该车辆在已检合格充电桩(以下称“合格桩”)上进行充电的数据建立车辆在合格桩上充电的累计电能计算公式。假设该车辆在合格桩上充电时的累计电能示值为“实际”电能输出值 E_r ,利用计算公式可得到该车在待测充电桩(以下称“待测桩”)上充电的计算电能值 E_c ,进而可由误差公式得到其与累计电能示值 E_d 的平均相对误差(mean relative error, MRE)。




图1 直流充电桩远程计量性能
检定方法实现流程

Fig.1 Schematic diagram of remote metering
performance evaluation method of
DC charging piles

该方法主要包含3个模块,各模块的主要作用及特点如下:

a. 数据采集与处理。该模块为性能检定方法的基础,需要通过传感器或充电桩状态监测物联网,采集电动汽车在直流充电桩上的充电过程交互数据,得到的信息包括充电桩输出电压 u 、电流 i 、电池荷电状态(state of charge, SOC)值 C_{SOC} 、充电时长 t 、电池组最高温度 T_{max} 、电池组最低温度 T_{min} 及累计电能示值 E_d 。将数据进行预处理后存储至云端数据库,以便后续调用数据进行模型构建。

b. 累计电能计算模型。采用电动汽车在合格桩上的充电数据作为训练桩数据,将累计电能示值作为“实际”输出电能,即 $E_d=E_r$,以此拟合得到累计电能与其他各相关变量的函数关系(式(1))。由于累计电能与其他变量关系相对复杂,故本文采用深度神经网络(deep neural networks, DNN)模型^[13]训练,建立特定车辆在合格桩上的累计电能变化函数关系:

$$E_c = g(u, i, t, C_{SOC}, T_{max}, T_{min}) \tag{1}$$

c. 直流充电桩计量性能检定。利用式(1)计算电能值 E_c ,将待测桩上的累计电能示值 E_d 与 E_c 之间的MRE与检定规程要求的合格桩最大示值误差进行对比,远程完成直流充电桩的计量性能检定工作。

2 数据采集及预处理

2.1 数据来源

为真实反映现场充电过程中的累计电能变化关系,本文进行了30d现场试验,采集了7辆电动汽车(编号:EV1、EV2、EV3、EV4、EV5、EV6、EV7)及14个不同直流充电桩(编号:11号、12号、1737、1738、1740、

1741、5092、5093、5099、5091、5993、15994、15998、15999) 共计 125 次充电过程的原始数据。数据采集时间间隔为 250 ms,每次充电过程时长为 0.5 ~ 1.5 h,故每次充电过程可获得约 7 000 ~ 20 000 个原始数据。

2.2 数据预处理

原始数据中对各电动汽车的充电过程次数采样不均,需对无效、错误以及可能会加大计算误差的部分数据进行筛选清除,以保证后续累计电能计算的精度,如 EV7 及充电桩 5 091、5 099、1 737、1 738、1 740、1 741 充电次数过少(仅 1、2 次),故删除了相应数据。

某次充电过程各变量随充电时长的变化如图 2 所示。由于原始数据采集时间间隔非常小,充电过程中各变量随充电时长的变化为阶梯状,即同一 E_d 存在多组不同的 u 、 i 、 C_{SOC} 、 t 、 T_{max} 、 T_{min} ,后续累计电能的回归模型训练难以进行。因此,研究中按 C_{SOC} 每变化 1% 进行数据提取($0 \leq C_{SOC} \leq 100\%$),得到充电过程累计电能计算的有效数据。




图 2 某次充电过程中各变量随充电时长的变化

Fig. 2 Change of each variable with charging time during a charging process

2.3 变量相关性分析

本研究的核心是建立合格桩上的“实际”累计电能与其他各变量的关系模型,属于回归问题,可利用变量间的相关性分析进行变量筛选。图 3 为 EV4 在合格桩 15 998 上某次充电过程中电能随各变量的变化关系,电能与 C_{SOC} 、 u 、 T_{max} 、 T_{min} 、 t 、 i 的相关系数 R 分别为 0.986 4、0.971 8、0.975 2、0.972 6、0.924 7 和 -0.690 3。




图 3 EV4 充电过程电能 E_d 随各变量的变化

Fig. 3 Change of electric energy E_d with other variables in the charging process of EV4

由图 3 可知,充电过程中 E_d 与 u 、 t 、 T_{max} 、 T_{min} 均表现为正相关性,而与 i 呈现出一定程度的负相关性。从 R 的绝对值大小来看, E_d 与 C_{SOC} 的相关程度最高,其次是 u 、 T_{max} 、 T_{min} 、 t 、 i 与 E_d 的相关性程度最低(R 绝对值小于 0.7)。根据统计学理论, R 绝对值超过 0.8 时,变量具有高度相关性^[19],在回归分析中不可忽略。直流充电桩充电时一般为“快充”形式,需要采用控制系统对其输出电流按充电准备、充电、充电结束等主要阶段进行控制(图 3(b)阶梯形变化),使得 E_d 与 i 的相关系数最小,此外,理论上 u 与 i 存在一定耦合关系^[6]。因此,后续模型建立中,为减少模型训练时间和保证拟合精度,选择相关系数更高的 u ,而暂不考虑 i 。

3 累计电能计算的 DNN 模型

3.1 数据特征输入

3.1.1 数据集划分

本文利用合格桩上的充电过程数据建立累计电能与各变量间的关系,进而计算待测桩 E_d 误差。因此,同一车辆模型的训练数据集为经现场检定,电能计量误差合格的充电桩上的充电数据(实际检定示值 MRE 绝对值小于 1%,如表 1 所示),而用于模型效果评估的数据集则同时包含了合格与不合格的待测桩的数据。训练数据集用于特定车辆电能计算模型的学习训练,评估数据集用于待测桩的“实际”累计电能的计算,而后与充电桩显示电能进行比对,从而对待测桩的计量性能进行检定。以各电动汽车作为“量值传递”的量具建立的累计电能计算模型中,训练数据集采用 70% 的合格桩充电数据,30% 的合格桩充电数据以及全部不合格桩充电数据划入效果评估数据集。

3.1.2 数据归一化处理

由于各输入变量的计量单位不同,数值相差较大,为排除数值大小对神经网络权重的影响,必须先对变量数据做归一化处理,即利用重定比例的方法使每种输入变量使用相同的计量标准。重定比例的方法有很多,一般采用标准化方法^[20],将输入特征变量数据集转化为平均值为 0、标准差为 1 的数据集。

3.2 神经网络架构设计

由图 3 及各变量与累计电能的相关性分析结果可知,充电过程中累计电能与充电电流的相关性很低,为提高计算拟合精度,暂不考虑该变量。因此,神经网络架构设计如下:输出层的神经元数量为 1,输入层的神经元数量为 5,与输入变量数量一致(将 u 、 t 、 $T_{\max}$ 、 C_{SOC} 、 $T_{\min}$ 作为输入变量),中间隐含层的层数以及各层神经元数量决定着 DNN 模型的学习预测能力,通常根据经验以及神经网络参数优化过程选取。

3.3 模型参数设置

在 DNN 模型中,网络中间隐含层的层数及各层神经元数量、各层所用激活函数、优化器、损失函数等常被称为模型的超参数,它们共同决定着神经网络对于输入变量与输出变量间映射关系求解能力的强弱。利用电动汽车 EV2 在合格桩上的充电数据对 DNN 模型进行超参数择优。一般而言,在 DNN 模型建立过程中,超参数是局部寻优而非全局最优解,即首先通过经验选择一定超参数范围后,采用试错法进行寻优操作。回归分析问题中,通常采用均方误差(mean square error, MSE)作为损失函数,平均绝对误差(mean absolute error, MAE)作为评价指标,MSE、MAE 可表征预测值与实际值的偏差,当偏差值局部最小时,可认为超参数使模型具有最优效果。

3.3.1 隐含层层数及神经元数量

分别构建具有 2、3 层隐含层的 DNN 模型并在各隐含层搭配适当的激活函数。对中间隐含层各层的神经元数量,业内广泛运用的经验计算公式^[21]为

$$H = \sqrt{H_1 + H_0} + \alpha \tag{2}$$

$$H = \log_2 H_1 \tag{3}$$

$$H = \sqrt{H_1 H_0} \tag{4}$$

式中: H 为隐含层神经元数量; H_1 、 H_0 分别为输入、输出层神经元数量,文中 $H_1 = 5$ 、 $H_0 = 1$; α 为常数,取值范围为 $[1, 10]$ 。

由式(2)~(4)得到 H 在 2.24~12.45 范围内模型效果较优,采用试错法设置不同的隐含层数及各层神经元数量,对比模型计算同一批数据的结果与实际结果间的误差,择优选择隐含层层数及各层神经元数量。将各层神经元数量由 H 计算范围取整并适当扩大为 4、8、16。图 4、图 5 分别给出了其他超参数固定不

表 1 各直流充电桩实际检定示值 MRE 及检定结果
Table 1 Actual verification indication MRE of each DC charging pile and discrimination result

充电桩编号	实际检定示值 MRE/%	检定结果
15 993	0.649	合格
15 994	0.543	合格
15 998	0.420	合格
15 999	0.221	合格
11 号	0.220	合格
12 号	-0.040	合格
5 092	-2.927	不合格
5 093	-2.930	不合格

变时,2 层和 3 层隐含层及各层不同神经元数量对应的 DNN 模型评估数据集的偏差大小(H_3 为第三隐含层神经元数量)。隐含层激活函数设置为线性整流函数 ReLU、损失函数为 MSE、优化器为随机梯度下降(stochastic gradient descent, SGD)算法、评估准则为 MAE、每批次训练 20 组数据、最大迭代次数为 500。可以看出,当 DNN 具有 3 层隐含层,各层神经元数量分别为 16、16、8 时,模型结构最优(评估数据集的 MSE 及 MAE 相对最小)。最优两层隐含层的 DNN 模型评估数据集的 MAE 值为 $0.666\text{ kW}\cdot\text{h}$ (隐含层分别有 16、8 个神经元),而最优 3 层隐含层的 DNN 模型评估数据集的 MAE 值则为 $0.543\text{ kW}\cdot\text{h}$,3 层隐含层的 DNN 模型计算精度提升约 20%。因此,本文采用 3 层隐含层的 DNN 模型。




图 4 两层隐含层和各层不同神经元数量模型评估数据集偏差

Fig.4 Bias of dataset assessed by the model with two hidden layers and different number of neurons in each layer




图 5 3 层隐含层和各层不同神经元数量模型评估数据集偏差

Fig.5 Bias of dataset assessed by the model with three hidden layers and different number of neurons in each layer

3.3.2 其他超参数择优

类似地,激活函数、优化器等超参数的择优在上述最优网络架构下进行。其中,激活函数选用了较为常用的 tanh、ReLU、sigmoid 3 种进行组合尝试,优化器则分别选用了 SGD、Adam、RMSprop、Adagrad、Adadelta、Nadam、Adamax。结果表明,激活函数组合为 ReLU-tanh-tanh 时,模型评估数据集的偏差最小(MSE、MAE 分别为 $0.445\text{ (kW}\cdot\text{h)}^2$ 、 $0.447\text{ kW}\cdot\text{h}$);优化器为 SGD 时模型评估数据集的偏差最小(MSE、MAE 分别为 $0.698\text{ (kW}\cdot\text{h)}^2$ 、 $0.568\text{ kW}\cdot\text{h}$)。

综上,最佳 DNN 模型架构为:输入层 5 个神经元,第一、第二隐含层 16 个神经元,第三隐含层 8 个神经元,输出层 1 个神经元。其他超参数配置如下:第一隐含层采用 ReLU 激活函数,第二、第三隐含层采用 tanh 激活函数,损失函数指标采用 MSE,优化器为 SGD 算法,评估指标采用 MAE,每批次训练 20 组数据,最大迭代次数为 500。

4 结果与分析

4.1 累计电能计算的 DNN 模型训练

经过数据预处理后,数据中仅包含 6 辆不同的电动汽车和 8 个不同的直流充电桩。对不同电动汽车分别进行累计电能计算的 DNN 模型训练。图 6 为不同车辆数据训练的 DNN 模型输出累计电能 E_e 与合格桩累计电能示值 E_d 的对比。从图 6 可以看出,模型输出的累计电能值与合格桩显示的累计电能示值接近,拟合精度较高(各车辆模型输出累计电能的决定系数 $R^2>0.9980$),误差较小(各车辆模型输出累计电能的 MAE 小于 $0.0580\text{ kW}\cdot\text{h}$)。因此,将构建的 DNN 模型用于待测桩“实际”累计电能的计算。

4.2 待测桩的 MRE 计算

利用训练好的 DNN 模型对相应车辆在不同待测桩充电的“实际”累计电能进行计算,并计算其与充电桩累计电能示值的 MRE,计算结果如表 2 所示。由表 2 可知,在利用 DNN 模型计算各充电桩“实际”累计电能时,同




图 6 不同车辆数据训练的 DNN 模型 E_c 与 E_d 对比

Fig. 6 E_c and E_d comparison of DNN models trained on different vehicle data

一充电桩上会有不同的电动汽车进行充电作业(即电动汽车与直流充电桩不是一一对应关系,这是实现“量值传递”的前提),使得不同车辆数据训练的 DNN 模型对于相同充电桩计算得到的 MRE 具有不同值。

表 2 各待测桩累计电能计算结果示值 MRE

Table 2 Indication MRE of calculation results of the accumulated electrical energy of each pile to be measured					
车辆编号	充电桩编号	MRE/%	车辆编号	充电桩编号	MRE/%
EV1	15998	-0.327	EV2	15993	0.730
	15999	0.157		15994	0.570
	5092	-2.520		5093	-1.760
	5093	-5.050			
			EV3	11 号	-0.741
				12 号	0.250
			EV4	11 号	0.745
				12 号	0.253
			EV5	11 号	3.002
				12 号	-0.402
			EV6	11 号	-0.244
				12 号	-1.830

4.3 待测桩的计量性能检定效果评估

将各车辆数据训练的 DNN 模型计算所得的某待测桩“实际”累计电能示值 MRE 求平均值从而消除不同车辆数据训练模型的影响,得到各待测桩最终的“实际”累计电能示值 MRE,结果如表 3 所示。由表 3 可知,模型计算得到的各待测桩示值 MRE 与实际检定示值 MRE(表 1)间差值的绝对值小于 1%(除 15998 号充电桩的差值为-0.747%,其余各桩的差值均在-0.5%~0.5%间),表明模型计算结果可靠。本文建立的 DNN 模型对 8 个待测桩的计量性能评估结果与实际检定结果完全一致,证实了所提出的直流充电桩远程计量性能检定方法的可行性。

5 结 论

- a. 电动汽车充电过程中电池荷电状态对充电桩累计电能影响最大,电流的影响最小。
- b. 基于“量值传递”原理构建的直流充电桩累计电能计算的 DNN 模型,可通过远程数据采集,对待测桩的“实际”累计电能进行准确计算,计算结果的示值误差与实际检定示值误差间差值的绝对值小于 1%。本文提出的直流充电桩远程计量性能检定方法可实现高效的直流充电桩计量性能评估。

参考文献:

[1] 周浩营. 低碳经济视角下我国新能源汽车的发展[J]. 时代汽车, 2021(20): 90-91. (ZHOU Haoying. The development of

表 3 DNN 模型对各待测桩的计算和检定结果

Table 3 Calculation and verification results of the DNN model for each pile to be measured

充电桩编号	模型计算结果示值 MRE/%	与实际检定示值 MRE 的差值/%	模型检定结果
15993	0.732	0.083	合格
15994	0.569	0.026	合格
15998	-0.327	-0.747	合格
15999	0.157	-0.064	合格
11 号	0.454	0.234	合格
12 号	-0.309	-0.269	合格
5092	-2.519	0.409	不合格
5093	-3.409	-0.482	不合格

China's new energy vehicles from the perspective of low-carbon economy[J]. Auto Time,2021(20):90-91. (in Chinese))

[2] 张越月.“双碳”目标下新能源汽车堪当大任[J]. 新能源科技,2021(9):7-9. (ZHANG Yueyue. Under the dual carbon target,new energy vehicles are worthy of great responsibility[J]. New Energy Technology,2021(9):7-9. (in Chinese))

[3] 杨梅,李文强,刘建波,等. 电动汽车充电桩/机校验仪国内技术现状及溯源研究[J]. 电测与仪表,2022,59(7):36-41. (YANG Mei,LI Wenqiang,LIU Jianbo,et al. Research on domestic technology status and traceability of electric vehicle charging pile/machine calibrator[J]. Electrical Measurement & Instrumentation,2022,59(7):36-41. (in Chinese))

[4] 张洪宝,彭璐,许鹏飞,等. 电动汽车充电桩计量检定的研究[J]. 计量与测试技术,2019,46(3):29-31. (ZHANG Hongbao,PENG Lu,XU Pengfei,et al. Research on measurement and verification of electric vehicle charging pile[J]. Metrology & Measurement Technique,2019,46(3):29-31. (in Chinese))

[5] 魏长赞,倪福生,戴伟,等. 绞吸挖泥船横移过程的预测控制系统研究[J]. 机械设计与制造工程,2018,47(1):70-74. (WEI Changyun,NI Fusheng,DAI Wei,et al. The predictive control for the swing process of a cutter suction dredger[J]. Machine Design and Manufacturing Engineering,2018,47(1):70-74. (in Chinese))

[6] 刘浩宇,何泽昊,吕伟嘉,等. 电动汽车交直流充电桩检测装置探索与设计[J]. 通信电源技术,2018,35(11):114-115. (LIU Haoyu,HE Zehao,LYU Weijia,et al. Exploration and design of electric vehicle AC and DC charging pile detection device[J]. Telecom Power Technologies,2018,35(11):114-115. (in Chinese))

[7] 叶佳旻,陈洁琼. 电动汽车充电桩检定新模式的思考[J]. 中国质量监管,2021(4):70-71. (YE Jiamin,CHEN Jieqiong. Thoughts on the new mode of electric vehicle charging pile verification[J]. China Quality Supervision,2021(4):70-71. (in Chinese))

[8] 曾博,李刚,韩帅,等. 电动汽车充电桩直流电能表检定系统[J]. 中国计量,2014(7):80-82. (ZENG Bo,LI Gang,HAN Shuai,et al. Verification system of electric vehicle charging pile DC energy meter[J]. China Metrology,2014(7):80-82. (in Chinese))

[9] 林勇,赵斯衍. 车载式直流充电桩计量检定平台的设计[J]. 电子测试,2020(14):21-22. (LIN Yong,ZHAO Sijie. Design of vehicle mounted DC charging pile measurement and verification platform[J]. Electronic Test,2020(14):21-22. (in Chinese))

[10] 徐卫亚,徐伟,闫龙,等. 基于 LM-BP 和 SVR 的倾倒变形体变形预测[J]. 河海大学学报(自然科学版),2021,49(1):64-69. (XU Weiya,XU Wei,YAN Long,et al. Deformation prediction of toppling deformed slope based on LM-BP and SVR[J]. Journal of Hohai University (Natural Sciences),2021,49(1):64-69. (in Chinese))

[11] 刘凡,陆小敏,徐丹,等. 海浪预报方法研究进展[J]. 河海大学学报(自然科学版),2021,49(5):387-393. (LIU Fan,LU Xiaomin,XU Dan,et al. Research progress of ocean waves forecasting method[J]. Journal of Hohai University (Natural Sciences),2021,49(5):387-393. (in Chinese))

[12] 张石,郑东健,陈卓研. 基于改进 PSO-RF 算法的大坝变形预测模型[J]. 水利水电科技进步,2022,42(6):39-44. (ZHANG Shi,ZHENG Dongjian,CHEN Zhuoyan. Dam deformation prediction model based on improved PSO-RF algorithm[J]. Advances in Science and Technology of Water Resources,2022,42(6):39-44. (in Chinese))

[13] 赵翔,陈良亮,李明贞,等. 一种基于深度神经网络的直流充电桩故障诊断方法[J]. 电测与仪表,2021,58(6):148-152. (ZHAO Xiang,CHEN Liangliang,LI Mingzhen,et al. A fault diagnosis method for DC charging pile based on deep neural network[J]. Electrical Measurement & Instrumentation,2021,58(6):148-152. (in Chinese))

[14] 王森,孙永辉,周衍,等. 计及误差时间相依性的风电功率超短期条件概率预测[J]. 电力自动化设备,2022,42(11):40-46. (WANG Sen,SUN Yonghui,ZHOU Yan,et al. Ultra-short term conditional probability prediction of wind power considering error time dependence[J]. Electric Power Automation Equipment,2022,42(11):40-46. (in Chinese))

[15] 王朋,孙永辉,翟苏巍,等. 基于小波长短期记忆网络的风电功率超短期概率预测[J]. 南京信息工程大学学报(自然科学版),2019,11(4):460-466. (WANG Peng,SUN Yonghui,ZHAI Suwei,et al. Ultra-short-term probability prediction of wind power based on wavelet decomposition and long short-term memory network[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition),2019,11(4):460-466. (in Chinese))

[16] 孙叶,唐琳,苏冰,等. 基于深度学习算法的电力变压器故障识别研究[J]. 微型电脑应用,2021,37(12):74-77. (SUN Ye,TANG Lin,SU Bing,et al. Research on power transformer fault recognition based on deep learning algorithm[J]. Microcomputer Applications,2021,37(12):74-77. (in Chinese))

[17] 马鑫. 基于特征增强的变压器故障识别方法:以溪洛渡电站为例[D]. 郑州:华北水利水电大学,2021.

[18] 张世瑶,贺玉彬,周新志. 基于深度学习的道路表面裂缝检测方法[J]. 科学技术与工程,2021,21(15):6380-6385. (ZHANG Shiyao,HE Yubin,ZHOU Xinzhi. Road surface crack detection method based on deep learning[J]. Science Technology and Engineering,2021,21(15):6380-6385. (in Chinese))

[19] 汪冬华. 多元统计分析与 SPSS 应用[M]. 上海:华东理工大学出版社,2010.

[20] 翟海保,王兴志,葛敏辉,等. 基于改进卷积神经网络的输电线路故障诊断方法[J]. 电气自动化,2021,43(2):105-108. (ZHAI Haibao,WANG Xingzhi,GE Minhui,et al. Fault diagnosis method for transmission lines based on the improved convolutional neural network[J]. Electrical Automation,2021,43(2):105-108. (in Chinese))

[21] 王小川,史峰,郁磊,等. MATLAB 神经网络 43 个案例分析[M]. 北京:北京航空航天大学出版社,2013:8-9.