

基于样本扩容和数据驱动的台区理论线损计算方法

贾轩¹,许吉凯¹,任艺婧²,刘德才¹,许强¹,张利^{2*}

(1.国网山东省电力公司聊城供电公司,山东聊城 252004; 2.电网智能化调度与控制教育部重点实验室(山东大学),山东济南 250061)

摘要:针对目前台区理论线损数据驱动研究中面临高质量数据样本规模不足的问题,提出一种基于样本扩容和数据驱动的台区理论线损计算方法。构建生成对抗网络,采用 Adam 优化器优化确定网络参数;对台区样本进行 K-means 聚类分析,提出依据轮廓系数和误差平方和优选聚类数目的方法,通过台区合理分类有效降低人工神经网络训练的计算量;基于扩容后的样本集训练各类台区,建立台区理论线损的人工神经网络分析模型。采用山东省聊城市某地的台区实际数据进行仿真分析,结果表明,所提方法可有效扩容样本集,提升人工神经网络模型的训练效果,提高台区理论线损分析的精度。

关键词:样本扩容;生成对抗网络;数据驱动;人工神经网络;台区线损

中图分类号:TM744

文献标志码:A

引用格式:贾轩,许吉凯,任艺婧,等. 基于样本扩容和数据驱动的台区理论线损计算方法[J]. 山东大学学报(工学版),2025,55(3):158-164.

JIA Xuan, XU Jikai, REN Yijing, et al. Calculation method of theoretical line loss in transformer districts based on sample expansion and data-driven[J]. Journal of Shandong University (Engineering Science), 2025, 55(3):158-164.

Calculation method of theoretical line loss in transformer districts based on sample expansion and data-driven

JIA Xuan¹, XU Jikai¹, REN Yijing², LIU Decai¹, XU Qiang¹, ZHANG Li^{2*}

(1. Liaocheng Power Supply Company State Grid Shandong Electric Power Company, Liaocheng 252004, Shandong, China;
2. Key Laboratory of Power System Intelligent Dispatch and Control, Ministry of Education (Shandong University), Jinan 250061, Shandong, China)

Abstract: Aiming at the problem of insufficient scale of high-quality data samples for data-driven research on theoretical line loss analysis of transformer districts, a calculation method of theoretical line loss in transformer districts based on sample expansion and data-driven was proposed. A generative adversarial network was constructed, and the Adam optimizer was used to optimize the network parameters. The transformer districts samples were analyzed by K-means clustering analysis, while a method for selecting the optimal number of clusters was built based on silhouette coefficient and sum of squared errors. The proper classification of the transformer districts effectively reduced the computational burden of artificial neural network training. The artificial neural network model for theoretical line loss analysis of transformer districts was established through training on each class of transformer districts with the expanded sample set. Simulations were conducted to verify the proposed method by using actual transformer districts data collected from an urban area in Liaocheng City, Shandong Province. The results showed that the sample set was effectively expanded, the training effectiveness of the artificial neural network model was improved, and higher accuracy was achieved in the theoretical line loss analysis of transformer districts.

Keywords: sample expansion; generative adversarial network; data-driven; artificial neural network; line loss of transformer districts

收稿日期:2024-05-09

基金项目:国网山东省电力公司科技资助项目(520611210005)

第一作者简介:贾轩(1987—),男,山东聊城人,高级工程师,硕士,主要研究方向为通信。E-mail:523949003@qq.com

*通信作者简介:张利(1967—),女,江苏启东人,副教授,硕士生导师,博士,主要研究方向为电力系统运行与控制。

E-mail:yzhangli@sdu.edu.cn

0 引言

化石燃料使用带来的环境污染与气温升高已成为当前全球各国面临的严峻挑战之一。为实现“双碳”目标,电力工业作为能源生产、传输的重点行业,在减排、降碳方面的作用不容忽视,提高能源利用效率、降低电网损耗是关键工作之一^[1-2]。台区线损在电网各电压等级损耗中占比较大,做好理论线损分析,为合理制定降损方案提供可靠依据^[3]。

过去低压台区由于量测手段不健全,理论线损计算大都采用工程近似算法^[4]和前推回代算法^[5]。为方便计算,工程近似算法多采用简化假设,不能充分考虑电网复杂的拓扑结构,难以考虑三相负荷不平衡等运行状态因素,计算准确度不高。前推回代算法计算量大,对元件数量众多、拓扑结构复杂的台区可操作性不高。随着分布式光伏的大量接入,台区实际工况更加变化万千,上述解析分析方法难以灵活适应,无法对台区理论线损做出全面分析^[6]。

随着人工智能技术和信息技术的快速发展,基于数据驱动的智能算法在电力系统分析领域得到广泛应用^[7-9]。在配电网线损分析中,决策树^[10]、支持向量机^[11]、人工神经网络^[12-13]等算法都得到一定研究,为具有非线性、数据间存在复杂相关关系的台区理论线损计算开辟新的研究方向。基于人工神经网络的台区理论线损计算方法经不断改进,应用效果得到进一步提升^[14]。但台区作为低压配电网的末端环节,常常因技术或人为问题导致数据采集效果不尽如人意,数据突变、缺少等质量问题时有发生,难以建立充足的数据驱动分析样本集,不能保证计算模型的训练效果。

实现数据驱动的台区理论线损分析的首要条件,是如何在高质量数据有限的情况下构建足够起支撑作用的样本集^[15]。这是提高大数据处理算法准确率的关键。数据增强技术是一种强大的工具,通过利用辅助数据集或信息,使有限数据产生与更多数据相当的效果。使用数据增强技术目的在于显著提升模型的泛化能力和性能,使模型在面对新的、未见过的数据时,能够更准确地做出预测和判断。常用的数据增强方法包括过采样法和合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)方法等^[16]。过采样法通过复制现有样本或生成合成的新数据点增加少数类样本,但仅对原始样本做简单复制使生成样本与原始数据过于相似,容易出现过拟合问题。

SMOTE方法采用线性插值在种子点和其最邻近点之间生成新的少数类样本,其中种子点在少数类样本中随机选择。这种方法生成的新样本可能与多数类样本发生重叠,导致样本多样性下降。在图像大数据处理领域出现许多新的数据增强技术,其中变分自编码器(variational autoencoder, VAE)^[17]和生成对抗网络(generative adversarial network, GAN)^[18]在样本增殖方面均取得很好的效果,逐步应用到电力数据处理方面^[19-21]。其中,GAN是一种无监督数据生成模型,根据判别器与生成器需达到纳什均衡确定生成数据,生成样本与原始数据的分布不完全相同,可显著提高后续数据驱动分析的准确率。

在上述研究基础上,本研究针对目前台区高质量数据样本数量不足,难以满足台区理论线损数据驱动分析的问题,提出一种基于生成对抗网络的台区线损样本扩容方法,并在此基础上采用神经网络算法建立台区理论线损的数据驱动分析方法。分析和仿真结果表明,通过生成对抗网络扩充样本,可建立充足的台区线损数据驱动分析样本集,提高模型训练效果,增强台区理论线损分析模型的泛化能力和准确率。

1 基于生成对抗网络的台区样本扩容

1.1 GAN 基本原理

GAN通过生成网络(生成器 G)和判别网络(判别器 D)的不断对抗,构成一个动态博弈过程,实现两个网络的动态纳什平衡,整体过程如图1所示。

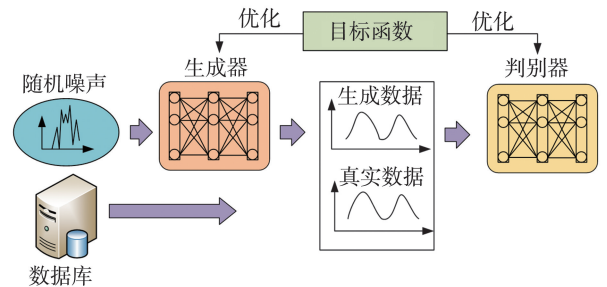


图1 生成对抗网络模型结构

Fig.1 Generate adversarial network model structure

生成网络不断结合噪声生成假数据,与原始数据一起输入判别网络中,判别网络对数据的真实来源进行判断,输出一个概率表示数据的真实度,用于对生成网络和判别网络的权重进行调节。当判别网络无法区分数据是生成数据还是原始数据(即

无法判断数据的真假)时,建立最优数据生成对抗网络模型。

GAN 模型的目标函数为

$$\min_G \max_D \{f(D, G) = E_{X \sim p_{\text{data}}}(x) [\lg D(x)] + E_{X \sim p_z}(z) [\lg(1 - D(G(z)))]\}, \quad (1)$$

式中: $f(D, G)$ 为生成样本与真实数据的差异度; $E_{X \sim p_{\text{data}}}(x)$ 为真实数据 x 的数学期望; $E_{X \sim p_z}(z)$ 为生成样本 z 的数学期望; $D(x)$ 为判别器给出的数据来自原始数据库的概率, $D(x) = p_{\text{data}} / (p_{\text{data}} + p_z)$, 其中 p_{data} 为真实数据分布, p_z 为生成数据分布; $D(G(z))$ 为判别器给出的数据来自生成器的概率, $D(G(z)) = p_z / (p_{\text{data}} + p_z)$ 。该目标函数可分为生成器与判别器两部分理解。生成器的目标函数为 $\min_G f(D, G) = E_{X \sim p_z}(z) [\lg(1 - D(G(z)))]$, 判别器的目标函数为 $\max_D f(D, G) = E_{X \sim p_{\text{data}}}(x) [\lg D(x)] + E_{X \sim p_z}(z) [\lg(1 - D(G(z)))]$ 。生成器的目标函数为

求最小化,因为生成器追求逼真还原真实数据,让生成数据与真实数据在判别器中无法区分,即期望 $D(G(z))$ 趋向于 1。判别器的目标函数为求最大化,因为判别器的作用是判别样本是真实的还是生成的,当数据判别为真实样本时, $D(G(z))$ 赋值为 1, 当数据判别为生成样本时, $D(G(z))$ 赋值为 0, 训练的最终目标是使生成数据无法识别,即 $D(G(z))$ 期望越来越接近 0。生成器的目标是欺骗判别器,生成让判别器无法识别真假的数据;判别器的目标是尽可能准确辨识数据,使真实数据与生成数据明显不同。生成器和判别器通过交替迭代的对抗训练不断调整参数,逐渐优化式(1),直到两个网络达成动态纳什平衡,即 $D(G(z)) = 0.5$, 最优对抗网络建立。

1.2 基于 GAN 的台区样本扩容

本研究生成对抗网络中,生成器和判别器的结构均采用全连接神经网络,具体结构参数如表 1 所示。


表 1 GAN 生成器与判别器结构
Table 1 GAN generator and discriminator structure

GAN 结构	第一层			第二层		第三层		
	神经元数	激活函数	输入数据数	神经元数	激活函数	神经元数	激活函数	输出数据数
生成器	25	tanh	20	25	tanh	1	Linear	1
判别器	25	tanh	9	25	tanh	1	Sigmoid	1


生成器的 3 层全连接网络分别采用 tanh 和 Linear 激活函数。Linear 激活函数在保持生成数据本身差异性方面具有很好的优势。判别器也采用 3 层全连接网络结构,但第三层激活函数与生成器不同,为 Sigmoid 函数,用于输出 $[0, 1]$ 区间的数据真假判别概率。3 种激活函数的笛卡尔坐标图如图 2 所示。由图 2 可知: Sigmoid 激活函数具有很好的加快收敛效果; tanh 函数趋于极值时,斜率比 Sigmoid 函数更大,可将负输入映射为强负值,零输入映射至最接近 0 的位置。因此,针对输入台区样本特征的识别, tanh 函数可在循环过程中使台区特征效果明显化。本研究 GAN 结构中隐含层神经元的设置依据参考文献[22],当输入样本量与输出样本量确定时,隐含层神经元数量

$$P_{\text{hidden}} = \sqrt{P_{\text{in}} + P_{\text{out}}} + \delta, \quad (2)$$

式中: δ 为可变参量, $\delta \in [1, 10]$, 本研究设置 $\delta = 9$; P_{in} 为输入训练样本数量; P_{out} 为输出样本数量。采用 Adam 优化器对两个网络的参数进行优化,分别采用均方误差 E_{MS} 、交叉熵损失函数作为生成器和判别器的损失函数。在训练 GAN 的过程中,生成器和判别器通过交替训练更新网络参数。



(a) Sigmoid 函数



(b) tanh 函数

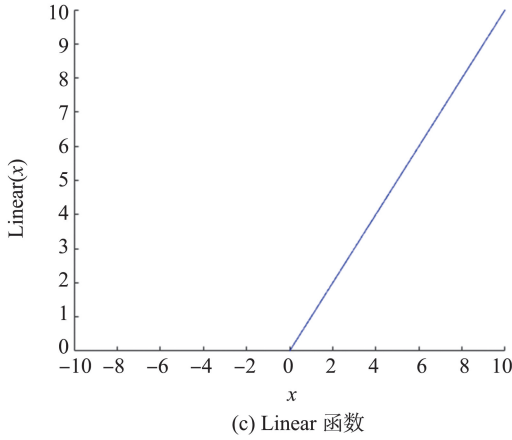


图2 激活函数笛卡尔坐标图

Fig.2 Plot of activation function in Cartesian coordinates

2 基于样本扩容的台区理论线损计算模型

文献[13]提出一种初始聚类中心确定方法,建立基于改进聚类算法和反向传播(back propagation, BP)神经网络的台区线损计算模型。文献[14]在文献[13]的基础上对输入变量的选择进行优化,从更多台区特征指标中通过灰色关联度分析确定与台区线损关联度高且不冗余的一组特征量,包括负荷曲线形状系数、平均日最大功率、居民容量、非居民容量、居民用户比例等,建立计算效果更好的台区线损计算BP神经网络模型。其中,BP神经网络由输入层、隐藏层和输出层组成。本研究在上述研究基础上,结合样本扩容,进一步改进K-means聚类,建立新的台区理论线损计算模型,流程图如图3所示。

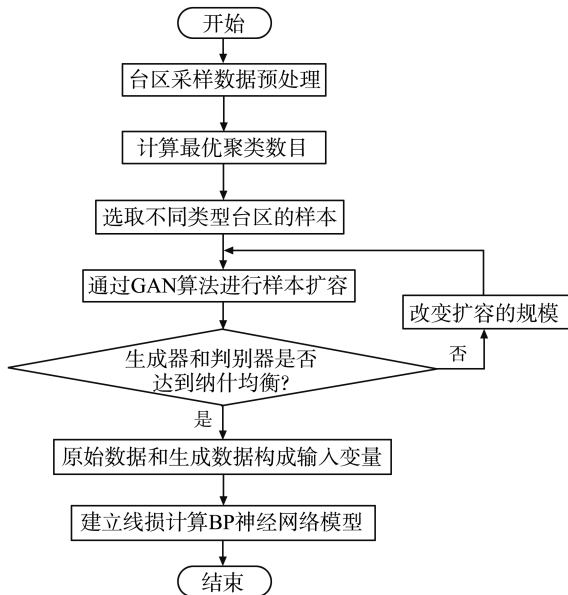


图3 基于样本扩容的台区理论线损计算流程图

Fig.3 Flow chart of theoretical line loss calculation based on sample expansion

对K-means聚类算法进行改进时,本研究着眼于聚类数K的确定问题,引入轮廓系数和误差平方和,为选择合适的K提供科学依据,在聚类效果和算法收敛速度之间达到最佳平衡。

轮廓系数用于衡量簇内样本的紧密度和簇间样本的分离度,综合评估聚类结果的优劣。设数据簇为 $X_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}, i = 1, 2, \dots, m$,其中 x_{ij} 为样本点。聚类后形成N个数据簇。 x_{ij} 的轮廓系数

$$S_{ij}(x_{ij}) = \begin{cases} 1 - \frac{p(x_{ij})}{q(x_{ij})}, & p(x_{ij}) < q(x_{ij}) \\ 0, & p(x_{ij}) = q(x_{ij}) \\ \frac{p(x_{ij})}{q(x_{ij})}, & p(x_{ij}) > q(x_{ij}) \end{cases}, \quad (3)$$

式中, $p(x_{ij})$ 为 x_{ij} 与簇内其他样本点的最小平均距离, $q(x_{ij})$ 为 x_{ij} 与非本簇样本点的最小平均距离。轮廓系数的取值范围为 $[-1, 1]$,轮廓系数越接近1,代表样本点在聚类内部的分布越紧密,即同一簇内样本点之间的相似度越高,聚类效果越优异;轮廓系数越接近-1,表示样本点在聚类内部的分布越松散,即同一簇内样本点之间的差异性越大,聚类效果越不佳。

误差平方和 S_{SE} 表示样本点与其对应预测值之间差的平方和,是衡量模型预测值与实际值之间误差的统计量,计算式为

$$S_{SE} = \sum_{i=1}^K \sum_{x_{ij} \in X_i} |x_{ij} - C_i|^2, \quad (4)$$

式中 C_i 为簇中所有样本的均值。随着聚类数K增大, S_{SE} 逐渐减小,当 S_{SE} 趋于平缓时,K对应的聚合结果簇内与簇间分布较为平衡,此时的K为最佳聚类数。

在建立BP神经网络时,采取灰色关联度对特征参数进行优选。将影响线损的特征参数指标作为比较序列 Y_1 ,台区线损作为参考序列 Y_0 。其中 $y_0(k)$ 、 $y_1(k)$ 分别为 Y_1 和 Y_0 的第k个数列。比较序列 $|y_0(k) - y_1(k)|$ 关于k和i求最小值和最大值的计算式分别为

$$Z_{\min}(y_0, y_1) = \min_i \min_k |y_0(k) - y_1(k)|, \quad (5)$$

$$Z_{\max}(y_0, y_1) = \max_i \max_k |y_0(k) - y_1(k)|. \quad (6)$$

各特征参数与台区线损率的关联系数

$$\xi_i(k) = \frac{Z_{\min}(y_0, y_1) + \rho Z_{\max}(y_0, y_1)}{|y_0(k) - y_1(k)| + \rho Z_{\max}(y_0, y_1)}, \quad (7)$$

式中, ρ 为分辨系数,本研究取 $\rho = 0.5$ 。由式(7)可得关联度

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k). \quad (8)$$

3 算例分析

本研究以2019年8月山东省聊城市某地台区数据作为研究对象,首先进行台区样本扩容,然后进行聚类分析,区分典型台区,最后针对各类型台区建立基于BP神经网络的台区理论线损分析模型。仿真试验条件如下:操作系统为Windows 10, CPU为3900x, GPU为RTX2080s, 编程语言采用Python 3.6, 深度学习框架采用Tensorflow 1.15.0, 编程工具采用Jupyter Notebook。

3.1 样本扩容有效性分析

按照文献[14]的数据清洗方法,对采集到的原始数据进行预处理,剔除不良数据。自178个台区分别提取样本,其中128个样本作为训练集,其余样本用作验证集。基于178个台区样本,学习率取0.001,逐步增大生成器规模进行仿真,观察判别器的输出概率。不同生成器规模下判别器的输出概率曲线如图4所示。

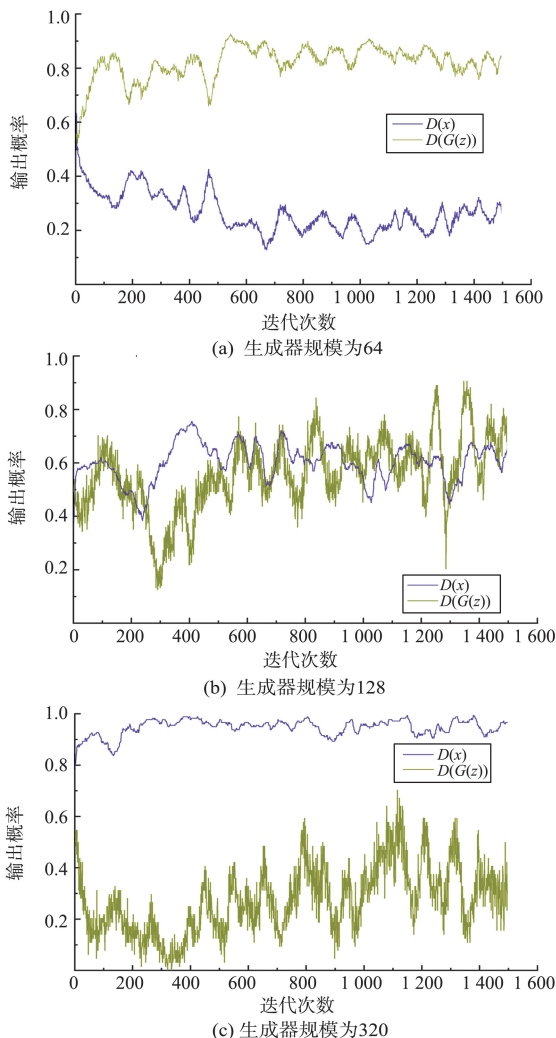


图4 不同生成器规模下判别器的输出概率曲线
Fig.4 Output probability curve of discriminator under different generator size

由图4(a)可知,当生成器生成数据规模为64时,真实数据的判定概率接近1,假数据的判定概率接近0,此时GAN未能达到纳什平衡;由图4(b)可知,当生成器生成数据规模为128时,真实数据和假数据的判定概率都接近0.5,此时,生成数据和真实数据已无法区分,生成数据最接近真实数据分布;由图4(c)可知,当生成器生成数据规模为320时,真实数据的判定概率接近0,假数据的判定概率接近1,说明判别器将真数据与假数据混淆,出现模型过拟合现象。因此,针对本研究的台区样本扩容,当生成器生成数据规模与原始数据比例接近1:1时,生成样本质量最佳。

3.2 台区理论线损计算

将GAN扩展生成的样本与真实数据一起训练,用于建立基于BP神经网络的台区理论线损计算模型。

令聚类数 K 从2到6递增,分别计算相应 K 下聚类结果的轮廓系数和 S_{SE} 。当 $K=3$ 时,轮廓系数最大, S_{SE} 曲线出现拐点,因此判断 $K=3$ 时聚类效果最好。

聚类分析将所有台区分为3类,各类台区中线损率与特征参数的关联度结果如表2所示。由表2可知,同一特征参数在不同台区中的关联度不同,反映不同台区包含的用户具有不同的用电规律。以居民容量为例,在第一类台区中居民用户占比高,因此居民容量与线损率有较高的关联度,在第三类台区中,居民用户比例小,工商用户比例增加,居民容量的关联度明显低于其他特征参数。因此,对于不同类的台区,将优选关联度高的特征参数作为BP神经网络训练的输入量。

表2 台区线损率与特征参数的关联度
Table 2 Correlation between line loss rate and the feature parameters in the transformer districts

特征参数	关联度		
	第一类台区	第二类台区	第三类台区
居民用户比例	0.971	0.865	0.589
负荷曲线形状系数	0.964	0.881	0.603
平均负载率	0.962	0.877	0.577
平均日最大功率	0.961	0.869	0.645
居民容量	0.958	0.848	0.447
非居民容量	0.957	0.867	0.656
非居民用户比例	0.953	0.859	0.897
光伏用户比例	0.943	0.844	0.584

不同样本量下,模型所得第一类台区的线损率与真实线损率的相对误差 E_r 分布如表3所示。由表3可知,样本扩容后,线损计算精度提高,因此,本

研究所提方法可明显改进 BP 神经网络在台区线损计算上的应用效果。

表3 不同样本量下第一类台区的线损率计算相对误差分布

Table 3 The relative error distribution of the calculated line loss rate on different data sets for the first class transformer districts

相对误差分布	样本比例/%	
	样本量 400	样本量 2 000
$0 \leq E_c < 5\%$	51.1	67.9
$5\% \leq E_c < 10\%$	19.2	11.1
$10\% \leq E_c < 15\%$	14.6	9.4
$E_c \geq 20\%$	15.1	11.6

4 结论

为推动台区理论线损的数据驱动分析,克服当前台区数据质量存在的问题,本研究提出一种基于样本扩容的台区理论线损计算方法。仿真分析表明:生成对抗网络可以在保持样本多样性的前提下,实现对样本的有效扩容,当生成样本与原始样本的比接近 1:1 时,生成样本质量最好;充足的样本保证计算模型训练的彻底性,可明显提高模型的计算精度,增强数据驱动分析方法的实用性。

本研究提出的样本扩容方法对其他因实际工况下样本采集困难而受影响的数据驱动研究也具有较好的参考价值。台区理论线损数据驱动分析不仅与样本质量与数量相关,先进的算法也必然带来促进作用。未来,将对更多人工神经网络(如卷积神经网络模型等)的应用开展进一步研究。

参考文献:

[1] 张勇军, 羿应棋, 李立涅, 等. 双碳目标驱动的新型低压配电系统技术展望[J]. 电力系统自动化, 2022, 46(22): 1-12.

ZHANG Yongjun, YI Yingqi, LI Licheng, et al. Prospect of new low-voltage distribution system technology driven by carbon emission peak and carbon neutrality targets[J]. Automation of Electric Power Systems, 2022, 46(22): 1-12.

[2] 袁学良, 杨月, 盛雪柔, 等. 碳达峰碳中和政策解析与对策建议[J]. 山东大学学报(工学版), 2023, 53(5): 132-141.

YUAN Xueliang, YANG Yue, SHENG Xuerou, et al. Policy analysis and countermeasures for achieving carbon peak and carbon neutrality[J]. Journal of Shandong University (Engineering Science), 2023, 53(5): 132-141.

[3] 田鑫, 牛新生, 朱秀波, 等. 低碳背景下山东电网最优

降损策略及评估方法[J]. 电力系统自动化, 2014, 38(17): 67-72.

TIAN Xin, NIU Xinsheng, ZHU Xiubo, et al. Optimal strategy and assessment method for minimizing power loss of Shandong power network under low-carbon background[J]. Automation of Electric Power Systems, 2014, 38(17): 67-72.

[4] QUEIROZ L M O, ROSELLI M A, CAVELLUCCI C, et al. Energy losses estimation in power distribution systems[J]. IEEE Transactions on Power Systems, 2012, 27(4): 1879-1887.

[5] 袁旭峰, 鹿振国, 许文强, 等. 基于前推回代三相潮流的低压台区理论线损计算研究[J]. 电测与仪表, 2014, 51(9): 1-5.

YUAN Xufeng, LU Zhenguo, XU Wenqiang, et al. Study on the theoretical line loss calculation of low-voltage transformer areas based on forward-back sweep three-phase power flow algorithm[J]. Electrical Measurement & Instrumentation, 2014, 51(9): 1-5.

[6] 马喜平, 贾嵘, 梁琛, 等. 高比例新能源接入下电力系统降损研究综述[J]. 电网技术, 2022, 46(11): 4305-4315.

MA Xiping, JIA Rong, LIANG Chen, et al. Review of researches on loss reduction in context of high penetration of renewable power generation[J]. Power System Technology, 2022, 46(11): 4305-4315.

[7] 于一潇, 杨佳峻, 杨明, 等. 基于深度强化学习的风电场储能系统预测决策一体化调度[J]. 电力系统自动化, 2021, 45(1): 132-140.

YU Yixiao, YANG Jiajun, YANG Ming, et al. Prediction and decision integrated scheduling of energy storage system in wind farm based on deep reinforcement learning[J]. Automation of Electric Power Systems, 2021, 45(1): 132-140.

[8] 赵磊, 栾文鹏, 王倩. 应用AMI数据的低压配电网精确线损分析[J]. 电网技术, 2015, 39(11): 3189-3194.

ZHAO Lei, LUAN Wenpeng, WANG Qian. Accurate line loss analysis of LV distribution network using AMI data[J]. Power System Technology, 2015, 39(11): 3189-3194.

[9] 章博, 卢峰, 董寒宇, 等. 基于决策树和数据驱动的零电量用户筛选方法[J]. 山东大学学报(工学版), 2019, 49(5): 29-36.

ZHANG Bo, LU Feng, DONG Hanyu, et al. Non-consumption users filtering algorithm based on decision tree and data-driven methods[J]. Journal of Shandong University (Engineering Science), 2019, 49(5): 29-36.

[10] 王守相, 周凯, 苏运. 基于随机森林算法的台区合理线损率估计方法[J]. 电力自动化设备, 2017, 37(11): 39-45.

- WANG Shouxiang, ZHOU Kai, SU Yun. Line loss rate estimation method of transformer district based on random forest algorithm[J]. *Electric Power Automation Equipment*, 2017, 37(11): 39-45.
- [11] YU H L, SUN C Y, YANG X B, et al. Fuzzy support vector machine with relative density information for classifying imbalanced data[J]. *IEEE Transactions on Fuzzy Systems*, 2019, 27(12): 2353-2367.
- [12] 马丽叶, 刘建恒, 卢志刚, 等. 基于深度置信网络的低压台区理论线损计算方法[J]. *电力自动化设备*, 2020, 40(8): 140-146.
- MA Liye, LIU Jianheng, LU Zhigang, et al. Theoretical line loss calculation method of low voltage transform district based on deep belief network[J]. *Electric Power Automation Equipment*, 2020, 40(8): 140-146.
- [13] 李亚, 刘丽平, 李柏青, 等. 基于改进 K -Means 聚类 and BP 神经网络的台区线损率计算方法[J]. *中国电机工程学报*, 2016, 36(17): 4543-4552.
- LI Ya, LIU Liping, LI Baiqing, et al. Calculation of line loss rate in transformer district based on improved K -Means clustering algorithm and BP neural network[J]. *Proceedings of the CSEE*, 2016, 36(17): 4543-4552.
- [14] REN Y J, ZHANG L, WANG H B, et al. Calculation method of the line loss rate in transformer district based on neural network with optimized input variables[C]//2020 IEEE 3rd Student Conference on Electrical Machines and Systems (SCEMS). Jinan, China: IEEE, 2020: 988-994.
- [15] 王丽, 于明仟, 刘文鹏, 等. 面向类不平衡数据的 K 近邻偏标记学习算法[J]. *山东大学学报(工学版)*, 2022, 52(3): 18-24.
- WANG Li, YU Mingqian, LIU Wenpeng, et al. K -nearest neighbor based partial label learning algorithm for class imbalanced data[J]. *Journal of Shandong University (Engineering Science)*, 2022, 52(3): 18-24.
- [16] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. *Journal of Artificial Intelligence Research*, 2002, 16: 321-357.
- [17] KINGMA D P, WELING M. Auto-encoding variational Bayes[EB/OL]. (2022-12-10)[2024-05-08]. <https://arxiv.org/abs/1312.6114v11>
- [18] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, USA: MIT, 2014: 2672-2680.
- [19] CHEN Y Z, WANG Y S, KIRSCHEN D, et al. Model-free renewable scenario generation using generative adversarial networks[J]. *IEEE Transactions on Power Systems*, 2018, 33(3): 3265-3275.
- [20] WANG C G, SHARIFNIA E, GAO Z, et al. Generating multivariate load states using a conditional variational autoencoder[J]. *Electric Power Systems Research*, 2022, 213: 108603.
- [21] 王德文, 杨凯华. 基于生成式对抗网络的窃电检测数据生成方法[J]. *电网技术*, 2020, 44(2): 775-782.
- WANG Dewen, YANG Kaihua. A data generation method for electricity theft detection using generative adversarial network[J]. *Power System Technology*, 2020, 44(2): 775-782.
- [22] UZAIR M, JAMIL N. Effects of hidden layers on the efficiency of neural networks[C]//2020 IEEE 23rd International Multitopic Conference (INMIC). Bahawalpur, Pakistan: IEEE, 2020: 9318195.

(编辑:孙亚彤)

(上接第157页)

- [27] 山东省统计局, 国家统计局山东调查总队. *山东统计年鉴 2023* [M]. 北京: 中国统计出版社, 2023: 56-201.
- [28] 国家电网有限公司. 国网新能源云[EB/OL]. (2021-04-20)[2024-06-15]. <https://sgnec.sgcc.com.cn>
- [29] ZHANG Y M, ZHANG X, JI X Q, et al. Distributional two-level synergetic unit commitment considering three scheduling states[J]. *Electric Power Systems Research*, 2022, 213: 108771.
- [30] JI X Q, YIN Z Y, ZHANG Y M, et al. Real-time robust forecasting-aided state estimation of power system based on data-driven models[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 125: 106412.
- [31] 张玉敏, 孙鹏凯, 吉兴全, 等. 考虑扩展碳排放流的综合能源系统低碳经济调度[J]. *电网技术*, 2023, 47(8): 3174-3183.
- ZHANG Yumin, SUN Pengkai, JI Xingquan, et al. Low-carbon economic dispatch of integrated energy system with augmented carbon emission flow[J]. *Power System Technology*, 2023, 47(8): 3174-3183.

(编辑:孙亚彤)