

DOI:10.20033/j.1003-7241.(2026)01-0147-05

基于极端梯度提升和检索增强的短期电力需求优化预测

孙伟¹, 邢璐¹, 史伟豪¹, 宋加帅², 李杨月²

(1. 国网安徽省电力有限公司电力科学研究院, 安徽 合肥 230601; 2. 安徽继远软件有限公司, 安徽 合肥 230088)

摘要:随着全球经济和人口的增长,电力需求的复杂性和多样性对电力系统提出了更高的要求。研究旨在优化短期电力需求预测以提高电力系统的经济性、安全性和可靠性。在自适应训练极端梯度提升的基础上,结合麻雀搜索算法,最终提出了一种新型短时电力需求预测模型。实验结果表明,新模型的预测准确度最高为91%,平均耗时为5秒,电力需求预测差值最低为0.66千瓦/小时,由此可知,研究所提出的新型预测模型在短期电力需求预测中具有显著优势,能够有效提升数据处理能力和预测准确性,也能够为该领域的技术发展提供一种新的参考。

关键词:极端梯度提升;特征提取;短期电力;预测;麻雀搜索算法

中图分类号: TM715

文献标志码: A

文章编号: 1003-7241(2026)01-0147-05

Optimization of short-term power demand forecasting based on extreme gradient boosting and retrieval enhancement

SUN Wei¹, XING Lu¹, SHI Weihao¹, SONG Jiashuai², LI Yangyue²

(1. State Grid Anhui Electric Power Research Institute, Hefei 230601, Anhui, China;

2. Anhui Jiyuan Software Co., Ltd., Hefei 230088, Anhui, China)

Abstract: As the global economy and population grow, the complexity and diversity of electricity demand place higher demands on the power system. The study aims to optimize short-term power demand forecasting to improve the economy, security and reliability of power systems. On the basis of adaptive training extreme gradient boosting, combined with the sparrow search algorithm, a new short-term power demand forecasting model is finally proposed. The experimental results show that the prediction accuracy of the new model is up to 91%, the average time consumed is 5 seconds, and the power demand prediction difference is as low as 0.66 kW/h. It can be seen that the new prediction model proposed by the research has significant advantages in short-term power demand prediction, and it can effectively improve the data processing capability and prediction accuracy, and it can also provide a new kind of reference for the technological development in this field.

Keywords: eXtreme gradient boosting; feature extraction; short-term power; forecasting; sparrow search algorithm

0 引言

电力需求预测不仅是电力系统规划的基础,也是电力市场运营、负荷调度和需求响应的重要依据。因此,优化电力需求预测模型,提升预测精度和效率,已成为电力系统研究的核心问题之一^[1-2]。其中,短期电力需求预测一般指对未来几个小时到几天内电力需求的预测,要求预测模型具备高精度和快速响应能力。王林等为了解决电力需求预测中的多因素影响问题和非线性问题,研究人员对粒子群算法的惯性权重和学习因子进行改进后,提出了一种非线性状态分析的电力需求预测模型。实验结果表明,该模型相比于同类型方法具有更高的预测精度和鲁棒性^[3]。René Carmona等在结合环境数据统计分析技术和

条件蒙特卡罗模拟后,针对特定地区的电力需求预测,构建了一种新模型。实验结果表明,该模型在得克萨斯州的电力需求预测中展示出了超高精确度和有效性^[4]。以上这些方法通过小样本学习和高维空间数据处理,以及时间序列分析的方式进行需求预测,虽然能够在一定程度上解决短时电力需求预测问题,但长久使用发现,仍存在需求预测不准确、耗时较长、成本较高等问题。近年来,极端梯度提升(eXtreme gradient boosting, XGBoost)作为一种高效的梯度提升算法,在大规模数据处理上表现出色^[5]。为此,研究在XGBoost的基础上创新性地构建了双层结构,同时引入了麻雀搜索算法(sparrow search algorithm, SSA)进行特征检索增强,增强了模型的泛化能力和预测准确性。研究的贡献在于提供了一种高效、准确的短期电力需

收稿日期:2024-07-22;录用日期:2024-08-08

基金项目:国网安徽省电力科技项目资助(52120524000B)

作者简介:孙伟(1986—),男,硕士,高级工程师,研究方向:电网数字化。

引用本文:孙伟,邢璐,史伟豪,等. 基于极端梯度提升和检索增强的短期电力需求优化预测[J]. 自动化技术与应用, 2026, 45(1):147-151. (SUN Wei, XING Lu, SHI Weihao, et al. Optimal short-term power demand forecasting based on extreme gradient boosting and retrieval enhancement[J]. Techniques of Automation and Applications, 2026, 45(1):147-151.)

求预测模型,能够更好地支持电力系统的规划与运行。

1 短期电力需求优化预测

1.1 短期电力需求预测模型构建

电力需求的特点是复杂多变,受多种因素影响,如季节变化、气候条件、经济发展水平、人口规模、工业生产活动等^[6]。电力需求预测是电力系统规划和运行的重要环节,其准确性直接影响电力系统的经济性、安全性和可靠性。电力需求预测的流程如图1所示。

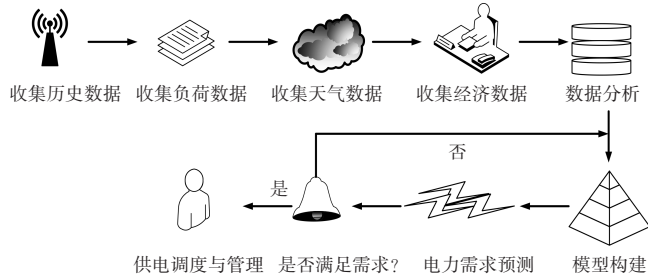


图1 电力需求预测流程

Fig. 1 Power demand forecasting process

由图1可知,首先收集整理历史负载数据,同时收集天气数据和经济数据进行数据准备^[7]。接着,所有数据被整合合并进行数据清洗和处理。之后进行特征提取,并构建预测模型。然后,利用构建好的模型进行电力需求预测。其中,短期电力需求的时间跨度短、预测精度要求高、影响因素多样。为此,研究引入了 XGBoost 算法,相较于其他方法, XGBoost 可以通过并行处理和优化的计算方式联合梯度提升,从而达到高效、准确、灵活的数据处理效果^[8-9]。其目标函数由损失函数和正则化项组成,计算公式为

$$\Gamma(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

式中, $\Gamma(\theta)$ 表示目标函数; $l(y_i, \hat{y}_i)$ 表示预测值 \hat{y}_i 与真实值 y_i 之间的误差,即损失函数; $\Omega(f_k)$ 表示正则化项; n 表示样本数量; K 表示树的数量。损失函数为

$$l(y_i, \hat{y}_i) = \frac{1}{2}(y_i - \hat{y}_i)^2 \quad (2)$$

式中, y_i 表示第 i 个样本的真实值; \hat{y}_i 表示第 i 个样本的预测值。正则化项的计算公式为

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (3)$$

式中, γ 表示叶子节点数量的惩罚系数; T 表示叶子节点数量; λ 表示正则化系数; ω_j 表示第 j 个叶子节点的权重。此时 XGBoost 模型的短期电力需求预测值计算公式为

$$\hat{y}_i = \sum_{k=1}^K f_k(\mathbf{x}_i) \quad (4)$$

式中, f_k 表示第 k 棵树的预测函数; \mathbf{x}_i 表示第 i 个样本的特征向量。在第 t 轮迭代中,新的预测值由之前的预测值和本轮新树的预测值之和得到,计算过程为

$$\hat{y}_i^t = \hat{y}_i^{t-1} + f_t(\mathbf{x}_i) \quad (5)$$

式中, \hat{y}_i^t 和 \hat{y}_i^{t-1} 分别表示第 t 轮次和第 $t-1$ 轮次迭代后的预

测值; f_t 表示第 t 轮次中新增的树的预测函数。由以上公式可知,当目标函数最小化时,此时的 XGBoost 模型训练拟合程度最佳^[10]。但若更换训练数据,则模型训练会十分耗时,且超参数的确定更加麻烦,如惩罚系数 γ 和叶子节点权重 ω_j 。为此,研究提出了一种自适应训练的 XGBoost 电力预测模型,该模型的结构如图2所示。

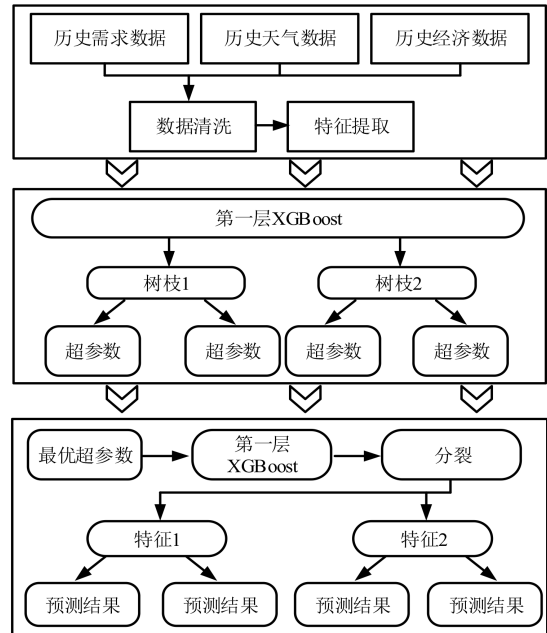


图2 基于自适应训练 XGBoost 的短期电力预测模型结构

Fig. 2 Structure of a short-term power forecasting model based on adaptive training of XGBoost

由图2可知,该模型分为两层结构。第一层 XGBoost 模型通过对输入数据的初步训练,快速评估不同超参数组合对模型性能的影响,并反馈最优的超参数组合。这一层的目标是自动化地调整和优化惩罚系数、叶子节点权重等关键超参数,以减少手动调参的工作量和时间消耗。在第二层 XGBoost 模型中,使用第一层模型确定的最优超参数进行短期电力负荷预测。这一层模型接收经过特征提取和处理后的输入数据,利用优化后的超参数进行训练和预测。通过这一两层结构的设计,模型不仅能够快速响应不同数据集的变化,同时也能保持高精度的预测效果。

1.2 模型的检索增强

研究发现传统的训练数据选取方式存在一定的局限性,例如历史数据的代表性不足,以及短期电力预测仅针对 1-3 天的时间跨度^[11-12]。因此,研究通过预处理步骤提取当前数据的特征向量,并在历史数据库中检索与之相似的历史数据^[13-14]。然后,将检索到的相似历史数据的特征与当前数据特征进行融合,形成增强后的特征向量。预处理步骤主要包括异常值检测、缺失值填补和降维处理。其中异常值可能由于数据采集错误、传输故障或其他原因导致,在 z-score 法中,异常值的判断计算公式为

$$z = \frac{s_i - \mu}{\sigma} \quad (6)$$

式中, z 表示 z-score 值; s_i 表示第 i 个需求数据点; μ 表示需求数据均值; σ 表示需求数据标准差。有且认为当 z-score 值的绝对值大于某个阈值, 通常为 3 时, 该数据点被认为是异常值。而缺失值的填补的方法有多种, 其中基于均值填补的方法更加稳定和有效, 计算公式为

$$e_i = \frac{1}{n} \sum_{j=1}^n u_j \quad (7)$$

式中, e_i 表示填补后的数据; u_j 表示非缺失数据。通过数据集的平均值来替代缺失值, 从而减小数据缺失对模型训练的影响。另外, 降维处理的目的是在保证数据特征信息的前提下, 减少特征数量, 降低计算复杂度, 防止模型过拟合。常用的方法为主成分分析法 (principal component analysis, PCA), PCA 的步骤包括计算数据的协方差矩阵、求解特征值和特征向量、选择主成分并进行数据转换^[15]。其中协方差矩阵计算公式为

$$C = \frac{1}{n} \sum_{i=1}^n (s_i - \mu)(u_j - \mu)^T \quad (8)$$

式中, C 表示协方差矩阵。特征值和特征向量的求解计算公式为

$$\begin{cases} Cv = \psi v \\ h_i = V^T(s_i - \mu) \end{cases} \quad (9)$$

式中, v 表示特性向量; ψ 表示特征值; y_i^* 表示降维后的数据; V 表示前 k 个特征向量组成的矩阵。在某些复杂和动态变化的电力需求场景中, 仅通过数据预处理来达到特征检索增强后的模型预测精度和稳定性仍有待提高。为此, 研究引入了 SSA。相较于其他方法, SSA 通过模拟麻雀觅食行为, 动态调整个体的位置和速度。从而保持全局搜索和局部搜索之间的平衡, 使模型具有强大的全局搜索能力。SSA 初始化特征种群的位置和速度计算公式为

$$X_i = X_{\min} + (X_{\max} - X_{\min}) \cdot \text{rand} \quad (10)$$

式中, X_i 表示第 i 只麻雀的位置, 即特征位置; X_{\max} 和 X_{\min} 分别表示位置的最大值和最小值; rand 表示随机数。位置与速度更新计算公式为

$$X_i(q+1) = X_i(q) + v_i(q) \quad (11)$$

式中, $X_i(q)$ 表示第 i 只麻雀在 q 时刻的位置; $v_i(q)$ 表示第 i 只麻雀在 q 时刻的速度。此时研究将 SSA 检索增强与自适应训练 XGBoost 的短期电力预测模型结合, 最终的新型短期电力需求预测模型流程如图 3 所示。




图 3 新型短期电力需求预测模型流程

Fig. 3 Flow of new short-term power demand forecasting model

由图 3 可知, 首先收集和整理历史负载数据、天气数据和经济数据, 然后进行数据清洗和处理。在数据准备完毕后, 采用 z-score 法进行异常值检测, 并使用均值填补的方法处理缺失值。接着, 应用 PCA 进行降维处理, 提取主要特征。在此基础上, 利用历史数据构建第一层 XGBoost 模型, 进行初步训练并评估模型效果。随后, 通过 SSA 优化算法进行超参数的全局搜索, 调整模型参数以提高预测精度。经过优化后的参数用于构建第二层 XGBoost 模型, 再次训练和评估模型效果。根据评估结果, 若满足精度要求, 则输出最终预测结果; 若不满足, 则进行参数调整或更换模型结构, 重复优化过程。最终, 优化后的 XGBoost 模型将用于实际的短期电力需求预测。

2 预测模型性能测试

研究搭建了合适的实验环境, CPU 设置为 8 核 AMDp Ryzen 7 4800H 处理器, GPU 为 NVIDIA GeForce, 内存为 32 GB,

磁盘类型为 SSD。设置 XGBoost 的正则化项为 0.3, 样本权重为 0.2。采用纽约市电力需求数据集和澳大利亚电力需求数据集为测试数据来源。其中纽约市电力需求数据集包含了纽约市不同区域的历史电力负荷数据, 如电力需求、温度、湿度等, 时间跨度涵盖多个年份, 数据粒度为小时级; 澳大利亚电力需求数据集涵盖了新南威尔士州、维多利亚州等多个州的电力负荷数据, 适合进行跨区域比较和分析。按照 8 : 2 的比例将测试数据分为训练集和测试集, 研究首先确定惩罚系数 γ 和叶子节点权重 ω_j 的超参数最佳值, 测试结果如图 4 所示。

图 4(a) 为训练集中不同惩罚系数和叶子节点权重的模型预测准确度测试结果, 图 4(b) 为测试集中不同惩罚系数和叶子节点权重的模型预测准确度测试结果。由图 4 可知, 在训练集和测试集中, 惩罚系数变化和叶子节点权重与模型预测准确率之间并非存在线性关系。在训练集中, 当惩罚系数为 0.06, 叶子节点权重为 0.4 时, 模型

的电力需求预测准确度最高为90%；在测试集中，当惩罚系数为0.06，叶子节点权重为0.6时，模型的电力需求预测准确度最高为91%。因此，可以说明惩罚系数与叶子节点权重取值分别为0.06和0.5时的模型性能最佳。研

究以响应速度为指标，同时引入了同类型且较为先进的电力需求预测模型进行了对比。例如长短时记忆网络预测模型、支持向量机模型和梯度提升决策树模型，各模型4天内测试结果如图5所示。

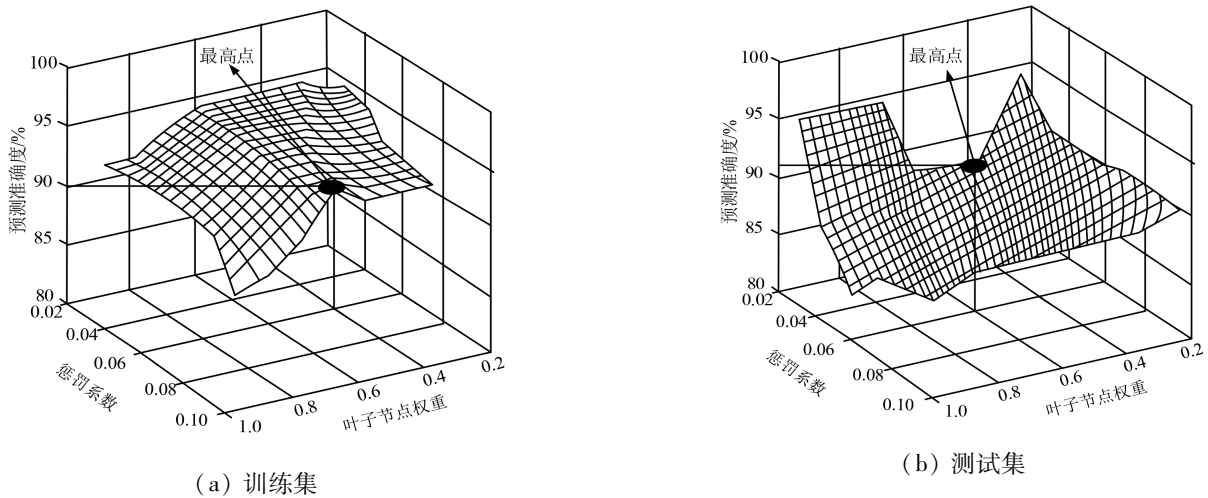


图4 不同惩罚系数和叶子节点权重的预测结果

Fig. 4 Prediction results with different penalty coefficients and leaf node weights




图5 不同模型的短时电力预测耗时对比

Fig. 5 Comparison of short-term power prediction time for different models

图5(a)为纽约市电力需求数据集下的各类模型耗时对比结果，图5(b)为澳大利亚电力需求数据集下的各类模型耗时对比结果。由图5可知，在预测1天、2天、3天和4天的电力需求时，不同模型的运行时间存在明显差异。长短期记忆网络模型在所有天数的预测中耗时最长，尤其是在纽约市数据集的第1天和第3天预测中，耗时分

别达到了11.3秒和13.0秒。而支持向量机模型和梯度提升决策树模型的耗时虽然较长短时记忆网络略短，但仍不及研究所提模型。相比之下，研究所提模型在4天内的电力需求预测平均时间为5秒，比长短时记忆网络缩减了6秒。研究继续对比了以上模型的电力需求实际预测和真实预测值，测试结果如表1所示。

表1 各模型的短期电力需求预测结果

Table 1 Short-term power demand forecast results for each model

数据集	模型	真实值/108(kW·h)	预测值/108(kW·h)	MAPE	MSE
纽约市电力需求数据集	长短期记忆网络模型	731.46	739.67	1.12	37.42
	支持向量机模型	813.24	818.56	0.65	28.38
	梯度提升决策树模型	712.89	714.37	0.26	16.79
	研究所提模型	802.31	802.97	0.21	13.27
澳大利亚电力需求数据集	长短期记忆网络模型	683.52	687.41	0.57	35.22
	支持向量机模型	711.18	708.39	0.39	24.17
	梯度提升决策树模型	788.63	790.54	0.24	19.68
	研究所提模型	721.24	722.15	0.13	13.22

由表1可知,在纽约市电力需求数据集中,长短期记忆网络模型、支持向量机模型、梯度提升决策树模型和研究所提模型的电力需求预测差值分别为 8.21 kW·h、5.32 kW·h、1.48 kW·h 和 0.66 kW·h。在澳大利亚电力需求数据集中,四种模型的预测差值分别为 3.89 kW·h、2.79 kW·h、1.91 kW·h 和 0.91 kW·h。此外,研究所提模型的 MAPE 值最低为 0.21, MSE 最低为 13.22, 该数值相较于其他三类模型存在明显的降低,说明研究所提模型通过 XGBoost 的决策数分类和 SSA 算法的特征检索增强,从而有效提升了其数据处理能力和预测有效性。

3 结论

针对短期电力需求预测中存在的复杂性和多样性挑战,研究采用自适应训练 XGBoost,通过引入 SSA 检索增强方法优化输入数据特征,实现特征检索增强和超参数全局搜索。研究结果表明,超参数中,惩罚系数与叶子节点权重取值分别为 0.06 和 0.5 时的模型性能最佳,此时的模型预测准确度最高为 91%。另外,在纽约市电力需求数据集上,模型平均预测耗时仅为 5 秒,电力需求预测差值最低为 0.66 kW·h,相较于长短期记忆网络模型,其预测平均时间缩短了 6 秒。在澳大利亚电力需求数据集上,研究所提模型的预测差值最低为 0.91 kW·h,此时的 MAPE 值最低为 0.21, MSE 最低为 13.22。该数值相较于长短期记忆网络模型、支持向量机模型和梯度提升决策树模型,表现出明显优势。综上所述,研究所提模型在短期电力需求预测中具有显著优势,能够有效提升数据处理能力和预测准确性。然而此次研究并未考虑天气情况对电力需求预测的影响,后续研究可纳入天气因素的考量,以进一步提高模型的全面性和有效性。

(上接第 131 页)

从图9可知,基于多因子优先级的自适应调度系统运行时,其吞吐量始终保持在 1 000 Mbps 以上,随着调度任务并发数量的变化会发生一定起伏,但从未低于预期设定吞吐量标准。证明新设计的系统应用到现实工程中,具有应用价值。

4 结论

针对现有通信指挥系统的局限性进行分析后,探索出一种基于多因子优先级的应急通信指挥自适应调度系统。考虑到应急场景的复杂性与多变性,实现了系统的高效、灵活与智能,为救援行动提供有力的信息保障。

参考文献

[1]王松江,盘大滨.基于集对分析的自然灾害应急管理评估方法研究[J].自然灾害学报,2023,32(4):104-116.
[2]班亚明,马宁,王玉清,等.基于多分支深度Q网络模型的卫星通信任务调度方法[J].无线电工程,2023,53(12):2921-2926.

参考文献

[1]苏振宇,林军.考虑气象因素的月度电力需求预测方法[J].数理统计与管理,2023,42(2):315-325.
[2]庞传军,尚学伟,张波,等.基于改进梯度提升算法的短期风电功率概率预测[J].电力系统自动化,2022,46(16):198-206.
[3]王林,王燕丽,安泽远.改进粒子群算法优化回声状态网络的电力需求预测研究[J].计算机工程与科学,2022,44(8):1457-1466.
[4]RENÉ CARMONA, YANG X. Joint granular model for load, solar and wind power scenario generation[J]. IEEE transactions on sustainable energy, 2024, 15(1): 674-686.
[5]戴璐平,沈嘉怡,张飞飞.基于时间序列算法的能源电力需求自动预测模型[J].自动化技术与应用,2024,43(1):49-51,65.
[6]陈光宇,杨锡勇,江海洋,等.高比例新能源接入下计及工业负荷特性的电网需求响应调控策略[J].电力自动化设备,2023,43(4):177-184.
[7]赵永宁,李卓,叶林,等.基于时空相关性的风电功率超短期自适应预测方法[J].电力系统保护与控制,2023,51(6):94-105.
[8]敬超,李珊珊.基于Stackelberg博弈定价的电力需求响应激励方法[J].计算机工程与设计,2023,44(12):3729-3737.
[9]王巍,袁泉,刘春晓,等.日前邀约模式下电力需求响应的聚合优化模型与方法[J].南方电网技术,2023,17(11):51-60.
[10]李逸超,刘伟峰,施泉生.块调度模式下的智慧小区自动需求响应模型[J].电测与仪表,2024,61(3):50-57.
[11]田鑫,王林钰,冀星沛,等.基于现代化基础设施体系政策要求的电网规模预测及优化需求[J].中国电力,2024,57(2):1-8.
[12]杨宇坤,曹刚,刘倩如.一种基于机器视觉的台区用电行为安全性检查技术[J].自动化技术与应用,2025,44(8):161-164,183.
[13]于琳琳,王泽,郝元钊,等.基于XGBoost的电力系统动态频率响应曲线预测方法[J].电力建设,2023,44(4):74-81.
[14]李灏恩,姜雨萌,戚宇辰,等.碳中和目标下电力需求预测体系构建及华东区域电力需求发展趋势研究[J].电网与清洁能源,2024,40(2):30-36.
[15]刘颂凯,袁铭洋,杨超,等.基于XGBoost和ASPSO的电力系统暂态稳定预防控制方法[J].电网与清洁能源,2023,39(10):9-18.

[3] JHA A, VERBURG A, TUKKARAJA P. Internet of things-based command center to improve emergency response in underground mines[J]. Safety and health at work, 2022, 13(1):40-50.
[4]刘敏杰,梁小斌.基于云平台及数据共享模式的线网及线路层融合调度指挥系统[J].都市快轨交通,2023,36(3):174-179.
[5]马尊云.煤矿应急救援可视化现场指挥系统的设计和实现[J].煤矿安全,2022,53(2):130-135.
[6]李文峰,朱彤,武立文,等.矿用本安型应急通信终端在矿下应急通信中的应用[J].煤炭技术,2023,42(6):212-216.
[7]汤兆平,邹扬,刘钰玲,等.基于Shapley值分配原则的铁路应急资源调度研究[J].重庆交通大学学报(自然科学版),2023,42(4):139-144.
[8]李华,郭皓杰,谢辉,等.基于信息熵的森林火灾应急指挥信息传递分析[J].中国安全科学学报,2023,33(1):80-87.
[9]王莉,费爱国,张平,等.智能应急指挥通信网络新框架与关键技术研究[J].通信学报,2023,44(6):1-11.
[10]段在鹏,俞思雅,黄月铃,等.面向多受灾区域与受限应急中心的双层耦合动态应急调度任务分配模型[J].安全与环境工程,2023,30(5):111-120.