

基于变分模态分解和混合深度神经网络的 短期电价预测

刘羿萱 杨 昭

(国网陕西省电力有限公司超高压公司, 西安 710025)

摘要 针对电力市场中电价数据的非线性、波动性及时序性等特征, 提出一种基于变分模态分解 (VMD) 和混合深度神经网络的短期电价预测方法。首先利用变分模态分解法将原始电价序列分解为多个平稳的子序列, 其次采用混合深度神经网络预测模型对各子序列分别进行预测并叠加, 得到最终的电价预测结果。该模型将卷积神经网络 (CNN) 和双向长短期记忆 (BiLSTM) 网络组合, 提取原始电价数据的空间特征和时间特征, 并结合 Attention 机制, 对原始电价序列中不同时刻电价数据的重要性进行区分。最后, 以美国 PJM 电力市场实际电价数据进行仿真分析, 并与多种电价预测模型进行对比, 结果验证了本文所提方法的有效性。

关键词: 短期电价预测; 变分模态分解 (VMD); 卷积神经网络 (CNN); 双向长短期记忆 (BiLSTM) 网络; 注意力机制

Short term electricity price prediction based on variational mode decomposition and hybrid deep neural network

LIU Yixuan YANG Zhao

(Ultra High Voltage Company of State Grid Shaanxi Electric Power Co., Ltd, Xi'an 710025)

Abstract A short term electricity price prediction method based on variational mode decomposition and hybrid deep neural network is proposed to address the characteristics of nonlinearity, volatility, and timeliness in electricity price data in the electricity market. Firstly, the original electricity price sequence is decomposed into multiple stationary subsequences using variational mode decomposition (VMD). Secondly, a hybrid deep neural network prediction model is used to predict and superimpose each subsequence separately, obtaining the final electricity price prediction result. This model combines convolutional neural network (CNN) and bidirectional long short term memory (BiLSTM) network to effectively extract spatial and temporal features of the original electricity price data, and combines attention mechanism to effectively distinguish the importance of electricity price data at different times in the original electricity price sequence. Finally, simulation analysis is conducted using actual electricity price data from the PJM electricity market in the United States, and the effectiveness of the proposed method is verified by comparing multiple electricity price prediction models.

Keywords: short term electricity price prediction; variational mode decomposition (VMD); convolutional neural networks (CNN); bidirectional long short term memory (BiLSTM) network; attention mechanism

0 引言

电价是电力市场交易中的关键因素。风光等新

能源的随机性和波动性引起市场电价剧烈波动, 平稳性大大降低。因此, 提高市场电价预测准确度, 有助于加快形成统一的电力市场体系^[1]。

当前,国内外研究学者在电价预测方面进行了大量研究。电价预测方法基本分为四种:时间序列法、传统机器学习算法、深度学习算法,以及多种模型混合的组合预测方法。时间序列法包含指数平滑方法^[2]、自回归移动平均模型 (autoregressive integrated moving average model, ARIMA)方法^[3]等。时间序列方法原理简单,计算速度快,考虑了原始数据序列的时序性,但是泛化能力差,适合数据非线性不强、波动性小的序列。随着机器学习的不断发展,广大学者将其应用到市场电价预测领域。例如, BP神经网络^[4]、支持向量机^[5]、极限学习机^[6]及随机森林^[7]等,由于电价序列数据自相关性很强,传统机器学习算法能够缓解特征不易提取的问题,但存在对时序数据之间的关系特征挖掘不足的缺陷,导致预测准确度偏低。相比于上述方法,以深度学习为代表的新型人工智能算法通过构建深层网络模型,利用逐层抽象、逐层迭代的机制,弥补了有效特征不易提取的缺陷,解决了传统机器学习算法模型泛化性差的难题。文献[8]将小波变换和深度信念网络 (deep belief network, DBN) 结合在一起,实现对日前电价的预测;文献[9]考虑地域分布,提出一种基于图卷积神经网络与长短期记忆 (graph convolution network-long short term memory, GCN-LSTM) 网络的边际电价时空预测算法;文献[10]采用小波分解和双重注意力 (Attention) 机制时序卷积网络 (temporal convolutional network, TCN) 的日前电价预测模型;文献[11]提出一种基于注意力机制的卷积神经网络和双向门控循环单元 (convolutional neural network-bidirectional gated recurrent unit, CNN-BiGRU) 电价预测模型。为了达到更高的预测准确度,许多学者从不同角度改进电价预测模型。其一,短期电价具有均值回归的特性,且具有明显的周期性、非线性及不平稳性,若利用模式分解法先对原始电价序列进行分解,再对各分解后的子序列分别进行预测后叠加,可提高模型预测准确度。模式分解法有集合经验模态分解 (ensemble empirical mode decomposition, EEMD)^[12]、互补集合经验模态分解 (complementary ensemble empirical mode decomposition, CEEMD)^[13]及变分模态分解 (variational mode decomposition, VMD)^[14]。其二,引入注意力机制^[15],在电价预测过程中突出关键特征的作用,提高电价预测的准确度。

基于模式分解、深度学习和 Attention 机制的优

势,本文针对电价序列时序性和非线性强的特点,提出一种基于变分模态分解和混合深度神经网络的短期电价预测方法。其中,变分模态分解将原始不平稳的电价序列分解成多个平稳的子序列作为预测模型输入;卷积神经网络 (convolutional neural network, CNN) 能够有效提取非线性强的电价序列的非线性局部特征;双向长短期记忆 (bidirectional long short term memory, BiLSTM) 网络能够有效提取电价序列的双向时间特征,即同时考虑历史和未来的信息特征;注意力机制将 BiLSTM 层提取的时间特征进行重要性划分,以降低冗余数据对预测准确度的影响,从而更加关注于时间序列中的关键特征。最后,以美国 PJM (Pennsylvania-New Jersey-Maryland) 市场的真实电价数据为样本,与现有的集中预测模型进行对比,以验证本文所提出模型的有效性。

1 模型结构

1.1 变分模态分解

原始电价序列具有波动性大、非线性强等特征,利用原始电价序列直接训练预测模型无法充分利用其深度时间序列特征。因此,利用 VMD 将原始电价序列分解为多个平稳的子序列,以降低原始序列的波动性和非线性,提升预测准确度。

VMD^[16-17]对原始数据序列的分解过程如下:

1) 构建约束变分问题。将原始电价序列分解为 K 个模态,每个模态分解时均对应一个中心频率,目标函数为各个模态分量的估计带宽和最小,约束条件为所有模态分量和是原始序列,约束变分模型如式 (1) 所示。

$$\begin{cases} \min \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left\langle \delta_t + \frac{j}{\pi t} \right\rangle * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

式中: u_k 为第 k 个模态分量; ω_k 为 u_k 的中心频率; δ_t 为狄拉克函数; $*$ 为卷积运算符; K 为预设的模态数目; $f(t)$ 为原始信号。

2) 求解约束变分问题。引入二次惩罚因子 α 和 Lagrange 乘子 λ , 消除变分模型的约束条件, Lagrange 函数如式 (2) 所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (2)$$

利用交替方向乘子算法更新模态分量 u_k 及中心频率 ω_k , 如式 (3)、式 (4) 所示。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

式中: $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{u}(\omega)$ 、 $\hat{\lambda}(\omega)$ 为 $f(t)$ 、 $u_i(t)$ 、 $u(t)$ 、 $\lambda(t)$ 的傅里叶变换; ω 为对应中心频率; n 为迭代次数。

持续更新 u_k 及 ω_k , 直至满足要求。

1.2 卷积神经网络

CNN^[18] 主要由卷积层、池化层和全连接层构成。卷积层用来提取电价序列的输入特征, 通过对输入数据与卷积核元素的线性计算提取原始序列的线性特征, 利用非线性激活函数 ReLU 提取输入序列的非线性特征; 池化层用于压缩所提取的特征, 通过最大值或平均值处理, 生成更关键的特征信息, 提升泛化性; 全连接层用于将池化层生成的特征信息进行整合并一维展开, 实现 CNN 和 BiLSTM 之间的过渡。卷积神经网络结构如图 1 所示。




图 1 卷积神经网络结构

1.3 双向长短记忆网络

LSTM 网络通过添加遗忘门、输入门、输出门及记忆单元, 对传统循环神经网络 (recurrent neural network, RNN) 进行改善, 避免了 RNN 的梯度消失问题。LSTM 单元结构如图 2 所示。

单向 LSTM 只能挖掘单向时间序列特征信息, 无法挖掘双向时间序列特征信息。BiLSTM^[19] 由前向和后向 LSTM 构成, 通过双向 LSTM 共同挖掘时

间序列过去和未来的特征信息, 进一步提升模型预测准确度。BiLSTM 单元结构如图 3 所示。




图 2 LSTM 单元结构




图 3 BiLSTM 单元结构

1.4 注意力机制

通过引入 Attention^[20] 机制, 神经网络自动并有选择性地按照不同数据特征实现差异化权重分配, 为有效数据特征信息分配偏高的权重, 其余特征分配偏低的权重。Attention 单元结构如图 4 所示。

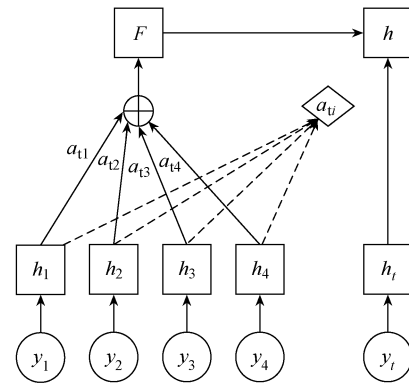


图 4 Attention 单元结构

2 预测流程

本文提出一种基于 VMD-CNN-BiLSTM-Attention 模型的日前电价预测方法, 具体预测流程如图 5 所示。在大量研究中, 组合模型显示出比传统单一模型更好的预测性能, 具有更高的准确性和稳定性, 不仅可提高特征提取的能力, 还可增强对时间序列数据的理解和预测能力。首先, 将原始电价数据通过 VMD 分解为多个平稳的子序列, 并划分训练样

本和测试样本。其次,构建 CNN-BiLSTM-Attention 电价预测模型。CNN-BiLSTM 结合了 CNN 和 BiLSTM 两种不同的神经网络结构,能够更好地处理时间序列数据。CNN 通过卷积操作捕捉数据的空间相关性,提取原始电价序列的非线性局部特征,BiLSTM 捕捉数据中的时间相关性,同时考虑历史和未来的信息。再者,通过引入 Attention 机制,能够根据序列中的每个时间步的重要性,动态地给不同时间步的信息赋予不同的权重,使模型更加关注序列中的重要部分,提升预测模型的准确性和泛化性。最后,保存训练完成的 VMD-CNN-BiLSTM-Attention 预测模型,对各子序列进行分别预测并叠加,并通过测试样本验证模型的有效性。

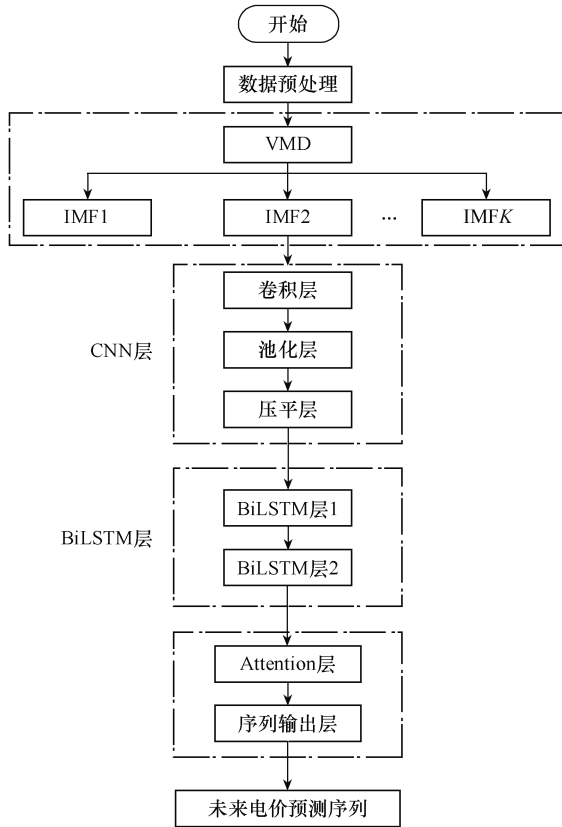


图5 预测流程

3 算例分析

3.1 实验数据说明

本文采用美国 PJM 电力市场 2016 年 1 月 1 日至 2016 年 1 月 31 日的历史电价数据进行仿真。数据间隔为 1h, 每天有 24 个数据点, 1 月份共有 744 个电价数据点。原始电价序列如图 6 所示。选取当月前 26 天数据为模型训练样本, 最后 5 天数据为模型测试样本。




图6 原始电价序列

3.2 误差指标

为了评估预测模型的准确度,使用方均根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 对电价预测模型的结果进行评价。

$$\varepsilon_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$\varepsilon_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$\varepsilon_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\% \quad (7)$$

式中: y_i 为第 i 个数据点的电价真实值; \hat{y}_i 为第 i 个数据点的电价预测值; n 为电价数据点的总数。

3.3 CNN-BiLSTM-Attention 有效性验证

为了验证本文提出的 CNN-BiLSTM-Attention 预测模型的有效性,分别与 BiLSTM 模型、CNN-BiLSTM 模型、天牛须搜索算法优化 BP 神经网络 (beetle antennae search-back propagation neural network, BAS-BPNN) 模型、灰狼算法优化极限学习机 (grey wolf optimizer-extreme learning machine, GWO-ELM) 模型对同一原始数据的预测结果进行对比。不同模型的电价预测结果如图 7 所示,不同模型的误差见表 1。

通过对比图 7 和表 1 可以得出:

1) CNN-BiLSTM-Attention 预测模型的预测效果最佳,各项误差均最小,验证了 CNN-BiLSTM-Attention 预测模型的有效性。

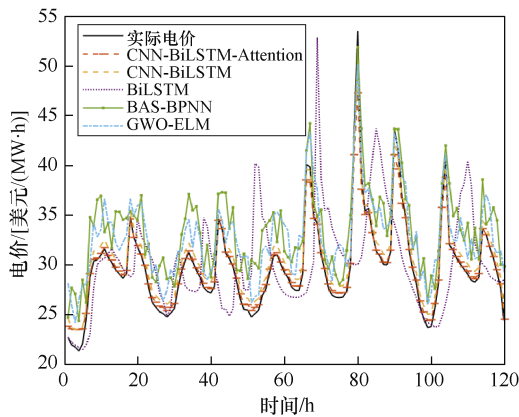


图7 不同模型的电价预测结果

表1 不同预测模型的误差

预测模型	ε_{RMSE}	ε_{MAE}	$\varepsilon_{MAPE}/\%$
CNN-BiLSTM-Attention	3.05	1.86	0.07
CNN-BiLSTM	3.19	2.25	0.08
BiLSTM	6.11	4.42	0.14
BAS-BPNN	3.91	3.55	0.13
GWO-ELM	3.43	3.16	0.11

2) CNN-BiLSTM 作为 BiLSTM 的改进模型,能够有效挖掘电价序列的数据空间特征,相比于 BiLSTM, CNN-BiLSTM 的 ε_{RMSE} 、 ε_{MAE} 、 ε_{MAPE} 分别降低了 47.79%、49.10%、42.86%,改进后的预测模型预测效果显著提升。

3) 组合模型的预测效果显著优于单一预测模型,新一代深度学习模型的预测效果优于传统机器学习算法模型。

3.4 VMD 有效性验证

下面对原始数据分别采用不分解、VMD 和经验模态分解 (empirical mode decomposition, EMD) 预处理的方法,得到各子序列,对各子序列分别通过 CNN-BiLSTM-Attention 预测模型进行预测,并将各子序列的预测结果叠加,获得最终预测电价。原始电价的 VMD 结果如图 8 所示,经分解后的测试集预测结果如图 9 所示,模型预测误差见表 2。

从图 9 和表 2 可以得出:

1) 相比于利用原始数据直接进行预测的 CNN-BiLSTM-Attention 模型,EMD-CNN-BiLSTM-Attention 模型和 VMD-CNN-BiLSTM-Attention 模型的 ε_{RMSE} 分别降低了 9.18%、15.41%, ε_{MAE} 分别降低了 1.61%、5.38%, ε_{MAPE} 分别降低了 14.29%、28.57%,通过“分解-预测-集成”的思想,能够让特征序列非线性更低、更平稳,进而提升模型的预测准确度。

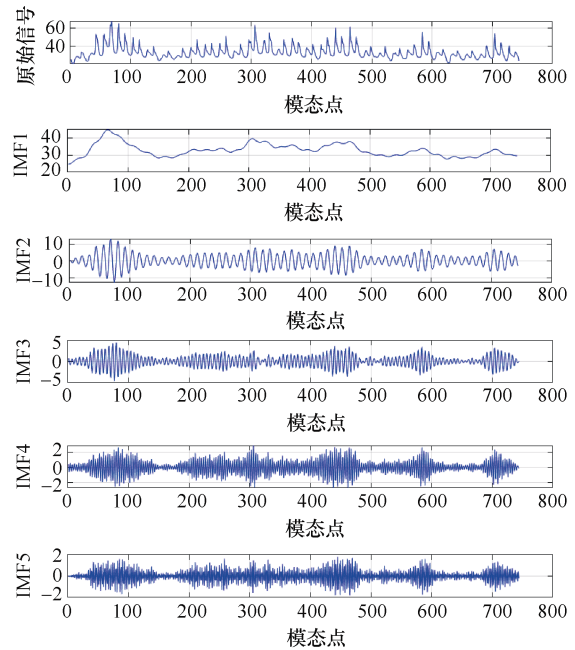


图8 原始电价的VMD结果




图9 经分解后的测试集预测结果

表2 模型预测误差

预测模型	ε_{RMSE}	ε_{MAE}	$\varepsilon_{MAPE}/\%$
CNN-BiLSTM-Attention	3.05	1.86	0.07
EMD-CNN-BiLSTM-Attention	2.77	1.83	0.06
VMD-CNN-BiLSTM-Attention	2.58	1.76	0.05

2) 相比于其他预测模型,VMD-CNN-BiLSTM-Attention 模型的预测准确度最高,验证了 VMD 应用于电价预测问题的有效性。

4 结论

针对电力市场的日前电价预测问题,本文提出了一种基于变分模态分解和混合深度神经网络的短期电价预测模型,首先对非线性强、不平稳的原始电价序列进行 VMD,分解为多个平稳的子序列,然

后输入 CNN-BiLSTM-Attention 网络进行训练和预测, 最后将各子序列预测结果叠加, 获得最终电价预测结果, 并利用美国 PJM 市场电价数据集验证了模型的有效性, 得到如下结论:

1) 通过 VMD 方法将原始序列分解为多个平稳的子序列, 可以显著降低原始电价序列“尖峰”处数据点的预测难度, 有效提高了模型的预测准确度。

2) 混合深度神经网络模型较其他模型具有更显著的数据特征分析与提取能力, 能够更好地处理电价序列存在的日周期性、波动性等特点, 同等条件下, 其预测性能较 CNN-BiLSTM、BiLSTM 等模型预测性能更优秀。

综上所述, 本文所提 VMD-CNN-BiLSTM-Attention 预测模型具有较高的预测准确度和较好的预测性能, 模型泛化能力高, 应用前景良好, 后续将进一步考虑天气、节假日、新能源发电等指标对电价预测的影响。

参考文献

- [1] 龚丹丹. 基于 VMD-ICOA-BiLSTM 混合模型的日前电价预测[J]. 电气技术, 2023, 24(11): 28-34.
- [2] 陈宇聪, 白晓清. 考虑时序二维变化的日前市场电价预测模型[J]. 电力系统及其自动化学报, 2024, 36(7): 22-29.
- [3] 张一泓, 朱国荣, 蔡永自, 等. 基于自回归积分滑动平均模型的日前电价预测[J]. 自动化技术与应用, 2020, 39(1): 125-129, 139.
- [4] 黄羹墙, 杨俊杰. 基于 BP 神经网络与马尔可夫链的短期电价预测[J]. 上海电力学院学报, 2017, 33(1): 1-3, 10.
- [5] 陈杰尧, 陶春华, 马光文, 等. 基于数据挖掘与支持向量机的现货市场出清价预测方法[J]. 电网与清洁能源, 2020, 36(10): 14-19, 27.
- [6] 殷豪, 曾云, 孟安波, 等. 基于奇异谱分析的短期电价预测[J]. 电力系统保护与控制, 2019, 47(1): 115-122.
- [7] 谢晓龙, 叶笑冬, 董亚明. 梯度提升随机森林模型及其在日前出清电价预测中的应用[J]. 计算机应用与软件, 2018, 35(9): 327-333.
- [8] 郭晨, 李雪瑞, 韩照洋, 等. 基于深度信念网络的日前电价预测[J]. 电力需求侧管理, 2022, 24(2): 86-91.
- [9] 韩升科, 胡飞虎, 陈之腾, 等. 基于 GCN-LSTM 的日前市场边际电价预测[J]. 中国电机工程学报, 2022, 42(9): 3276-3286.
- [10] 黄圆, 魏云冰, 童东兵, 等. 基于 WPD 和双重注意力机制 TCN 的短期电价预测[J]. 电工电能新技术, 2022, 41(6): 80-88.
- [11] 杨超, 冉启武, 罗德虎, 等. 基于注意力机制的 CNN-BiGRU 短期电价预测[J]. 电力系统及其自动化学报, 2024, 36(3): 22-29.
- [12] 许越, 李强, 崔晖. 基于 MIC-EEMD-改进 Informer 的含高比例清洁能源与储能的电力市场短期电价多步预测[J]. 电网技术, 2024, 48(3): 949-958.
- [13] 高诗博, 高阳, 戴菁. 基于 CEEMD-ISSA-LSSVM 的日前电力市场价格预测[J]. 沈阳工程学院学报(自然科学版), 2023, 19(2): 71-78.
- [14] 郭雪丽, 华大鹏, 包鹏宇, 等. 一种基于改进 VMD-PSO-CNN-LSTM 的短期电价预测方法[J]. 电力科学与技术学报, 2024, 39(2): 35-43.
- [15] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的 CNN-LSTM 短期电价预测[J]. 电力系统保护与控制, 2022, 50(17): 125-132.
- [16] 杨昭, 张钢, 赵俊杰, 等. 基于变分模态分解和改进粒子群算法优化最小二乘支持向量机的短期电价预测[J]. 电气技术, 2021, 22(10): 11-16.
- [17] 刘帼巾, 刘达明, 缪建华, 等. 基于变分模态分解和改进灰狼算法优化深度置信网络的自动转换开关故障识别[J]. 电工技术学报, 2024, 39(4): 1221-1233.
- [18] 司马文霞, 孙佳琪, 杨鸣, 等. 计及铁心非线性的变压器空间动态磁场加速计算方法[J/OL]. 电工技术学报, 1-16 [2024-10-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.240281>.
- [19] 钟吴君, 李培强, 涂春鸣. 基于 EEMD-CBAM-BiLSTM 的牵引负荷超短期预测[J/OL]. 电工技术学报, 1-16 [2024-10-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231515>.
- [20] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.

收稿日期: 2024-07-22

修回日期: 2024-09-20

作者简介

刘羿莹(1995—), 女, 陕西西安人, 工程师, 主要从事电力系统控制与运行、变电运维研究工作。