

基于LSTNet模型的配电台区短期电力负荷预测研究

顾吉鹏¹,邵亮¹,陆垂基¹,张有兵¹,张伟杰¹,杨吉峰²

(1.浙江工业大学 信息工程学院,浙江 杭州 310000;

2.国网浙江慈溪市供电有限公司,浙江 慈溪 315300)

摘要:短期电力负荷预测作为电力系统运行规划的重要依据,对电力系统的安全经济运行有重要意义。提出一种长期和短期时间序列网络(LSTNet)模型对配电台区的短期负荷变化进行预测。该模型用卷积神经网络(CNN)提取负荷数据间的局部依赖关系,用长短期记忆(LSTM)神经网络提取负荷数据长期变化趋势,再融合传统自回归模型解决神经网络对负荷数据极端值的不敏感问题,最后将某一配电台区的电力负荷数据用于网络的训练和预测过程中。通过仿真实验案例发现,相较于以往LSTM、双向长短期记忆神经网络(Bi-LSTM)和CNN-LSTM的预测模型,LSTNet模型在短期负荷预测方面更具优势、预测精度更高。

关键词:短期电力负荷预测;长期和短期时间序列网络;长短期记忆神经网络;卷积神经网络;自回归模型

中图分类号:TM715 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd24383

Research on Short-term Power Load Forecasting in Distribution Area Based on LSTNet Model

GU Jipeng¹, SHAO Liang¹, LU Chuiji¹, ZHANG Youbing¹, ZHANG Weijie¹, YANG Jifeng²

(1.College of Information Engineering, Zhejiang University of Technology, Hangzhou 310000, Zhejiang, China; 2.State Grid Zhejiang Cixi Power Supply Co., Ltd., Cixi 315300, Zhejiang, China)

Abstract: As an important basis of power system operation planning, short-term power load forecasting is great significant to the safe and economic operation of power system. A long-term and short-term time series network (LSTNet) model was proposed to predict the short-term load variation of distribution area. The model used convolutional neural network (CNN) to extract local dependencies between load data, and long and short term memory (LSTM) neural network to extract the long-term trend of load data, and then integrated the traditional autoregressive model to solve the problem that the neural network was insensitive to the extreme value of load data. Finally, the power load data of a distribution area was used in the network training and prediction process. Discovered by simulation experiment case, compared with LSTM, Bi-LSTM and CNN-LSTM prediction models, LSTNet model has more advantages and higher prediction accuracy in short-term load forecasting.

Key words: short-term power load forecasting; long-term and short-term time series network (LSTNet); long and short term memory (LSTM) neural network; convolutional neural network (CNN); autoregressive model

电力负荷预测在现代电力系统研究中占有重要地位,不仅是保障电力系统安全经济运行的前提,也是合理安排电网调度计划的依据^[1]。根据预测时长,负荷预测可分为短期、中长期、长期等主要形式^[2]。短期负荷预测是对电力负荷进行未来几分钟到1周的预测,精准的短期负荷预测将有助于制订合理的电力生产计划,避免电力资

源的过渡浪费,提高电力系统的经济效益^[3]。

根据时间跨度可将短期电力负荷预测分为日前负荷预测和周前负荷预测,可为电力负荷调度提供相关参考^[4-5]。随着电力系统监测技术和信息通讯技术的快速发展,越来越多的电力系统中安装了高精度的数据测量装置,收集的海量数据为精准的短期电力负荷预测奠定了数据基

基金项目:国家自然科学基金(51777193)

作者简介:顾吉鹏(1994—),男,博士研究生,Email:2026321998@qq.com

通讯作者:张有兵(1971—),男,博士生导师,教授,Email:youbingzhang@zjut.edu.cn

础^[6-7]。

负荷预测方法主要分为两大类:统计学方法和机器学习方法。统计学方法主要有自回归模型^[8]、卡尔曼滤波法^[9]、多元线性回归法^[10]等。统计学方法具有原理简单、快速建模的优点,但当样本数据过大时其预测效果一般。机器学习方法主要有灰色理论^[11]、神经网络^[12]、支持向量回归^[13]等。机器学习方法具有处理海量数据、预测精度高的优点,但其十分依赖于采集数据的精确性。文献[14]应用小波变异果蝇算法对支持向量机预测模型进行了改进,短期负荷预测精度得以提升。文献[15]在对负荷数据进行聚类分析的基础上,采用改进的BP神经网络进行短期负荷预测,预测结果满足要求。但上述两种方法都没有考虑负荷数据间的内在相关性,且当样本数据过多时容易陷入局部收敛。近年来,得益于计算机技术的不断进步,深度学习获得了学者们的广泛关注。在电力负荷预测领域,最为典型的模型就是长短时记忆神经网络(long and short term memory neural network, LSTM)。文献[16]利用LSTM进行短期负荷预测,相较于传统模型预测效果更好。文献[17]提出一种双向长短时记忆神经网络(bi-directional long and short term memory neural network, Bi-LSTM),之后成功应用于新能源电网的负荷预测中。LSTM模型在处理长时序数据时会存在梯度消失问题,文献[18]利用卷积神经网络(convolutional neural network, CNN)提取数据的特征向量,并将特征向量作为LSTM预测的依据,有效解决了梯度消失问题。文献[19]在Bi-LSTM的基础上引入注意力机制,通过注意力权重突出不同影响因素对用电负荷的影响,有效体现了负荷数据间的内部规律且提高了预测精度。

相较于单一的深度学习方法,经多种方法融合形成的组合深度学习方法更具预测的普适性,且预测精度更高^[20-22]。基于上述背景,提出利用长期和短期时间序列网络(long-term and short-term time series network, LSTNet)模型进行短期负荷预测,该方法可有效利用负荷数据间的局部依赖关系和负荷数据长期变化的周期特性进行预测。在此基础上加入自回归模型解决神经网络对负荷数据极端值的不敏感问题,进一步改善预测效果。通过与LSTM、Bi-LSTM和CNN-LSTM算法的对比,LSTNet模型在配电台区短期负荷预测方面的效果更优。

1 一维CNN和LSTM

1.1 一维CNN

CNN作为深度学习的典型代表算法之一,是一种包含卷积运算和具有深度解析结构的前馈型神经网络。CNN是根据生物的视觉机制构建的,其隐含层的卷积核参数共享机制和层间连接的稀疏特性,使网络的复杂度和需要调节的参数大大减少,避免了网络过拟合的风险。

本文所用的是一个不加池化层的全零填充的一维CNN,主要用于提取原始数据的抽象特征,如图1所示。假设输入的时间序列数据有 a 行 b 列,卷积核为 m 行 n 列。由于卷积核只在一个维度上滑动,且卷积核包含所有特征向量,所以卷积核宽度必须与输入时间序列数据的宽度一致,即 $n=b$,则第 i 个卷积核 c_i 作用在输入矩阵 X 上可表示为

$$a_i = c_i * X + b_i \quad (1)$$

式中: $*$ 表示卷积运算; b_i 为卷积偏置项。




图1 一维CNN计算过程

Fig.1 One dimensional CNN calculation process

1.2 LSTM网络

LSTM是循环神经网络(recurrent neural network, RNN)的变体,在一定程度上缓解了RNN在处理相对长时间序列数据时梯度消失的问题,但在处理超长时间序列数据时,LSTM仍然存在梯度消失的问题,下文中将给出对应的解决方法。图2为LSTM的基本结构。

LSTM的核心是门控单元,主要有三种:遗忘门、更新门和输出门。其中,遗忘门选择性地遗忘部分历史数据,更新门将当前保留信息与历史遗留数据进行信息融合,输出门衡量当前状态对隐含层的影响。LSTM的计算过程如下:




图2 LSTM的基本结构

Fig.2 Basic structure of LSTM

$$\Gamma_u^t = \sigma(W_u[a^{t-1}, h^t] + b_u) \quad (2)$$

$$\Gamma_n^t = \sigma(W_n[a^{t-1}, h^t] + b_n) \quad (3)$$

$$\Gamma_o^t = \sigma(W_o[a^{t-1}, h^t] + b_o) \quad (4)$$

$$c^t = \Gamma_o^t \odot \tilde{c}^t + \Gamma_n^t \odot c^{t-1} \quad (5)$$

$$\tilde{c}^t = \tanh(W_c[a^{t-1}, h^t] + b_c) \quad (6)$$

$$a_{LSTM}^t = \Gamma_o^t \odot c^t \quad (7)$$

其中

$$\sigma = 1/(1 + e^{-x})$$

$$\tanh = (e^x - e^{-x})/(e^x + e^{-x})$$

式中: $\Gamma_u^t, \Gamma_n^t, \Gamma_o^t, c^t$ 分别为 t 时刻更新门、遗忘门、输出门和记忆细胞的状态; W_u, W_n, W_o, W_c 和 b_u, b_n, b_o, b_c 分别为对应的权值矩阵和偏置项; $\sigma, \tanh$ 为激活函数; $\tilde{c}^t$ 为中间变量; a_{LSTM}^t 为LSTM网络的输出。

2 LSTNet 负荷预测模型的建立

2.1 数据预处理方法

现实生活中的数据大致都是不完整、缺失的,无法直接进行数据挖掘,或挖掘效果较差。为了提高数据挖掘的质量,产生了数据预处理技术。数据预处理是指对所收集的数据进行分析前所做的审核、筛选、排序等必要的处理方式。

数据预处理有很多方法:数据清理、数据集成、数据变换、数据规约等。数据归一化处理是常用的数据预处理方式,本文采用最值归一化对数据进行预处理,其公式如下:

$$x_{scale} = (x - x_{min})/(x_{max} - x_{min}) \quad (8)$$

式中: x 为实测数据; x_{min}, x_{max} 为实测数据的最小值、最大值。

2.2 LSTNet模型的基本结构

LSTNet模型由线性部分和非线性部分组成,线性部分包含时间序列数据中的周期性分量,非线性部分关注时间序列数据的局部极端情况。LSTNet模型的基本结构如图3所示。

非线性部分的第1层是一个不加池化层的全零填充的一维CNN,并使用 $ReLU$ 激活函数激活,则第 i 个卷积核 c_i 作用在输入矩阵 X 上可表示为




图3 LSTNet模型的基本结构

Fig.3 Basic structure of LSTNet model

$$a_i = \text{ReLU}(c_i * X + b_i) \quad (9)$$

其中

$$\text{ReLU}(x) = \max(0, x)$$

式中: $*$ 表示卷积运算; b_i 为卷积偏置项。

为解决LSTM在处理超长序列数据时出现的梯度消失问题,本文在LSTNet模型中加入了时间跳跃连接的LSTM网络组件,该组件利用了电力负荷的周期特性,比如:如果要预测某一天下午1:00整的电力负荷,参考历史数据中下午1:00整的电力负荷数据将会比参考这天上午、中午的负荷数据更具意义。然后将卷积的输出结果分别输入到LSTM组件与跳跃连接的LSTM组件中,具体的更新过程如下:

$$\Gamma_u^t = \sigma(W_u[a^{t-p}, h^t] + b_u) \quad (10)$$

$$\Gamma_n^t = \sigma(W_n[a^{t-p}, h^t] + b_n) \quad (11)$$

$$\Gamma_o^t = \sigma(W_o[a^{t-p}, h^t] + b_o) \quad (12)$$

$$c^t = \Gamma_o^t \odot \tilde{c}^t + \Gamma_n^t \odot c^{t-p} \quad (13)$$

$$\tilde{c}^t = \tanh(W_c[a^{t-p}, h^t] + b_c) \quad (14)$$

$$a_{S-LSTM}^t = \Gamma_o^t \odot c^t \quad (15)$$

在非线性部分的最后,使用一个全连接层来组合二者的输出。全连接层的输入是 t 时刻LSTM组件的隐态 a_{LSTM}^t 和 $t-p+1$ 时刻到 t 时刻跳过的隐态 a_{S-LSTM}^t 的加权组合,全连接层的输出可表示为

$$g_D^t = \sum_{i=0}^{p-1} W_{S-LSTM}^i a_{S-LSTM}^{t-i} + W_{LSTM} a_{LSTM}^t + b_D \quad (16)$$

式中: g_D^t 为非线性部分的输出; W_{LSTM}, W_{S-LSTM}^i 为权重; b_D 为偏置项。

除此之外,由于CNN和LSTM的非线性性质,导致神经网络对输入数据的极端值不敏感,这将对模型的预测精度产生较大影响。因此在LSTNet模型中加入了线性回归部分,线性回归部分由自回归模型组成,其过程如下:

$$g_L^t = \sum_{i=1}^n W_i x^{t-i} + b_L \quad (17)$$

式中: g_L^t, x^{t-i} 分别为线性部分的输出与输入; $W_i,$

b_L 分别为权重与偏置; n 为输入窗口的大小。

LSTNet模型的输出为线性和非线性输出结果相加后再经过Sigmoid激活函数后得到的结果 y' ,可由下式表示:

$$y' = \sigma(g'_D + g'_L) \quad (18)$$

2.3 模型精度的评价指标

本文采用均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和R2_score作为LSTNet预测模型的评价指标,计算公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (19)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (20)$$

$$R2_score = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (21)$$

其中

$$\bar{y}_i = \sum_{i=1}^N y_i / N$$

式中: $\hat{y}_i$ 为模型的预测值; y_i 为真实值; $\bar{y}_i$ 为真实值的平均值。

当 $RMSE=0$, $MAPE=0$, $R2_score=1$ 时,模型拟合效果最好。

2.4 短期负荷预测的流程

将建立的LSTNet模型用于电力负荷的短期预测过程中,具体的算法流程如图4所示。




图4 LSTNet模型负荷预测流程

Fig.4 LSTNet model load forecasting process

3 仿真实验案例

3.1 原始负荷数据分析

采用国网温州电力公司在某小区一个公共变压器上记录的负荷数据,即配电台区的电力负荷数据,该数据采样周期为15 min,总共12个月,

共记录35 133条数据。图5为一年的电力负荷变化曲线,小图中为本年第1周的负荷数据。




图5 电力负荷年变化曲线

Fig.5 Annual variation curve of power load

由图5可以看出,配电台区电力负荷年变化曲线呈现出强烈的非线性和季节性,即夏季的用电负荷高于其它季节,此特征与我国南方地区的用电负荷习惯一致。此外,电力负荷周变化曲线呈现出明显的周期特性,利用此特性可进行短期负荷预测研究,以便制订合理的电网调度计划。

3.2 负荷预测对比实验

为了突出LSTNet模型在短期负荷预测中的优势,本文还搭建了LSTM,Bi-LSTM,CNN-LSTM预测模型与之对比。这三个模型与LSTNet模型均使用了3.1节所提的数据集,训练次数均为100次。图6~图9分别为四种预测模型在一天与一周的时间尺度上的预测结果曲线与预测误差曲线。表1为四种预测模型在一天与一周的时间尺度上的模型精度的评价指标。




图6 电力负荷一天预测结果

Fig.6 One day power load forecast results




图7 电力负荷一天预测误差

Fig.7 One day power load forecast error




图8 电力负荷一周预测结果

Fig.8 Weekly power load forecast results

由图6~图9可以看出,不论是一天还是一周的时间尺度,这四种预测方法都能较好地预测配电台区电力负荷的变化,但本文预测方法的结果曲线最贴合真实的配电台区电力负荷变化曲线,其他三者负荷变动较大时的预测结果存在较大的偏差。同时,本文所提的电力负荷预测方法在一天与一周的时间尺度上均具有最小的误差,且误差曲线变动幅度也小于其他




图9 电力负荷一周预测误差

Fig.9 Weekly power load forecast error

表1 不同预测模型精度的评价指标

Tab.1 Accuracy evaluation index of different forecast models

预测模型	MSE/kW		MAPE/%		R2_score/%	
	一天	一周	一天	一周	一天	一周
LSTM	22.84	37.94	12.67	20.79	88.89	68.39
Bi-LSTM	22.08	32.03	10.79	16.37	89.62	77.50
CNN-LSTM	18.94	34.37	9.53	18.51	92.72	74.18
LSTNet	12.41	19.01	6.46	9.49	96.72	92.08

三种方法。

由表1可以看出,LSTNet模型在一天时间尺度上的 MSE 、 $MAPE$ 、 $R2_score$ 值分别为12.41, 6.46, 96.72; MSE 和 $MAPE$ 值小于CNN-LSTM, Bi-LSTM, LSTM模型的对应值,而 $R2_score$ 值大于CNN-LSTM, Bi-LSTM, LSTM模型的对应值,说明在四种模型中LSTNet模型在一天时间尺度上的预测精度最高,预测效果是最好的。此外,LSTNet模型在一周时间尺度上的 MSE 、 $MAPE$ 、 $R2_score$ 值分别为19.01, 9.49, 92.08, MSE 和 $MAPE$ 值在四种模型中最小, $R2_score$ 值在四种模型中最大,一周时间尺度的模型精度评价指标与一天时间尺度的模型评价指标具有相似的数值关系,说明在四种模型中LSTNet模型在一周时间尺度上同样取得最好的负荷预测效果。

3.3 负荷预测消融实验

为了验证LSTNet模型中各个组件对预测结果带来的作用,本文在一天和一周的时间尺度上将LSTNet模型的预测结果与其消融模型的预测结果进行对比分析。以LSTNet模型为基础,去掉

线性自回归组件后的模型为LSTNetW/OAR模型,去掉中间层跳跃连接的LSTM组件后的模型为LSTNetW/OSkip模型,去掉线性自回归组件与循环跳跃组件后的模型为基本的LSTM模型。图10~图13分别为LSTNet模型及其消融模型在一天与一周的时间尺度上的预测结果曲线与预测误差曲线。




图10 消融实验一天预测结果

Fig.10 One day forecast results of ablation experiment




图11 消融实验一天预测误差

Fig.11 One day forecast error of ablation experiment




图12 消融实验一周预测结果

Fig.12 One week forecast results of ablation experiment




图13 消融实验一周预测误差

Fig.13 One week forecast error of ablation experiment

由图10,图11可以看出,LSTNet模型在一天时间尺度上得到了最好的预测效果,其次是LSTNetW/OAR与LSTNetW/OSkip消融模型,最后是LSTM模型,体现了自回归组件与循环跳跃组件对提高预测精度的重要作用。此外,装配有线性自回归组件的LSTNet与LSTNetW/OSkip模型在数据变化极端时,具有较好的表现,体现了线性自回归组件具有缓解神经网络对数据的极端

值不敏感问题的作用。

由图12,图13可以看出,在一周的时间尺度上LSTNet模型仍然获得了最佳预测效果,相较于LSTNetW/OSkip消融模型与LSTM模型,LSTNet模型与LSTNetW/OAR模型的预测精度有较大的提高,体现了在较大时间尺度上,循环跳跃组件对提高预测精度具有可观的效果。

表2为LSTNet模型及其消融模型在一天与一周的时间尺度上的模型精度评价指标。

表2 LSTNet及其消融模型精度的评价指标

Tab.2 Accuracy evaluation index of LSTNet ablation experiment

预测模型	MSE/kW		MAPE/%		R2_score/%	
	一天	一周	一天	一周	一天	一周
LSTM	22.84	37.94	12.67	20.79	88.89	68.39
LSTNetW/OSkip	21.27	33.38	11.31	18.85	90.37	75.69
LSTNetW/OAR	19.92	24.41	9.95	12.17	91.55	86.97
LSTNet	12.41	19.01	6.46	9.49	96.72	92.08

4 结论

为提高短期负荷预测的精度,本文提出基于LSTNet模型的电力负荷预测方法,该模型由卷积神经网络、长短时记忆神经网络和自回归模型等部件组成,可兼顾负荷数据间的短期局部依赖关系和负荷数据长期变化趋势的特点,具有较高的预测精度。

将LSTNet,LSTM,Bi-LSTM,CNN-LSTM用于配电台区短期电力负荷预测的研究中,得到以下结论:1)LSTNet模型的预测精度高于LSTM,Bi-LSTM,CNN-LSTM,更适用于配电台区的短期负荷预测;2)循环跳跃组件和自回归模型作为LSTNet模型的组件时,在提高预测精度的同时可避免负荷数据极端值不敏感问题;3)组合的深度学习方法较单一的深度学习方法,更具预测问题的普适性,可用于光伏、风力、综合能源等其他领域的预测研究中。

参考文献

- [1] 陈弘川,蔡旭,孙国歧,等. 基于智能优化方法的相似日短期负荷预测[J]. 电力系统保护与控制,2021,49(13):121-127.
- [2] 胡威,张新燕,李振恩,等. 基于优化的VMD-mRMR-LSTM模型的短期负荷预测[J]. 电力系统保护与控制,2022,50(1):88-97.

- [3] CHEN Kunjin, CHEN Kunlong, WANG Qin, et al. Short-term load forecasting with deep residual networks[J]. IEEE Transactions on Smart Grid, 2019, 10(4):3943-3952.
- [4] LIN Weixuan, WU Di, BOULET Benoi, et al. Spatial-temporal residential short-term load forecasting via graph neural networks[J]. IEEE Transactions on Smart Grid, 2021, 12(6):5373-5384.
- [5] JALALI S, AHMADIAN S, KHOSRAVI A, et al. A novel evolutionary-based deep convolutional neural network model for intelligent load forecasting[J]. IEEE Transactions on Industrial Informatics, 2021, 17(12):8243-8253.
- [6] JIANG Huaiguang, ZHANG Yingchen, MULJADI Eduard, et al. A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization[J]. IEEE Transactions on Smart Grid, 2018, 9(4):3341-3350.
- [7] 姜建,刘海琼,李衡,等. 基于XGBoost的配电网线路峰值负荷预测方法[J]. 电力系统保护与控制,2021,49(16):119-127.
- [8] JEONG Dongyeon, PARK Chiwoo, KO Young Myoung. Short-term electric load forecasting for buildings using logistic mixture vector autoregressive model with curve registration[J]. Applied Energy, 2021, 282:1-14.
- [9] SHARMA Shalini, MAJUMDAR Angshul, ELVIRA Victor, et al. Short-term blind Kalman filtering for short-term load forecasting[J]. IEEE Transactions on Power System, 2020, 35(6):4916-4919.
- [10] FANG Junlong, XING Yu, FU Yu, et al. Rural power system load forecast based on principal component analysis[J]. Journal of Northeast Agricultural University (English Edition), 2015, 22(2):67-72.
- [11] FENG Jiawei, YANG Junyou, LI Yunlu. Load forecasting of electric vehicle charging station based on grey theory and neural network[J]. Energy Reports, 2021, 7(6):487-492.
- [12] FEKRI Mohammad Navid, GROLINGER Katarina, MIR Syed. Distributed load forecasting using smart meter data: federated learning with recurrent neural networks[J]. International Journal of Electrical Power and Energy Systems, 2022, 137:107669.1-107669.12.
- [13] LIU Haoming, TANG Yu, PU Yue, et al. Short-term load forecasting of multi-energy in integrated energy system based on multivariate phase space reconstruction and support vector regression mode[J]. Electric Power Systems Research, 2022, 210:1-10.
- [14] 熊军华,牛珂,张春歌,等. 基于小波变异果蝇优化支持向量机短期负荷预测方法研究[J]. 电力系统保护与控制,2017,

- 45(13):71-77.
- XIONG Junhua, NIU Ke, ZHANG Chunge, et al. LSSVM in short-term load forecasting based on wavelet transform and mutant fruit fly optimization algorithm[J]. Power System Protection and Control, 2017, 45(13):71-77.
- [15] 赵云,高泽璞,肖勇,等. 基于多层聚类和改进BP神经网络的短期负荷预测[J]. 武汉大学学报, 2019, 52(7):622-629.
- ZHAO Yun, GAO Zepu, XIAO Yong, et al. Short term load forecasting based on multilayer clustering and improved BP neural network[J]. Engineering Journal of Wuhan University, 2019, 52(7):622-629.
- [16] 陈卓,孙龙祥. 基于深度学习LSTM网络的短期电力负荷预测方法[J]. 电子技术, 2018, 47(1):39-41.
- CHEN Zhuo, SUN Longxiang. Short-term electrical load forecasting based on deep learning LSTM networks[J]. Electronics Design & Application, 2018, 47(1):39-41.
- [17] 杨龙,吴红斌,丁明,等. 新能源电网中考虑特征选择的Bi-LSTM网络短期负荷预测[J]. 电力系统自动化, 2021, 45(3):166-173.
- YANG Long, WU Hongbin, DING Ming, et al. Short-term load forecasting in renewable energy grid based on bi-directional long short-term memory network considering feature selection[J]. Automation of Electric Power Systems, 2021, 45(3):166-173.
- [18] 陆继翔,张琪培,杨志宏,等. 基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8):131-137.
- LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8):131-137.
- [19] 王继东,杜冲. 基于Attention-BiLSTM神经网络和气象数据修正的短期负荷预测模型[J]. 电力自动化设备, 2022, 42(4):172-177, 224.
- WANG Jidong, DU Chong. Short-term load prediction model based on Attention-BiLSTM neural network and meteorological data correction[J]. Electric Power Automation Equipment, 2022, 42(4):172-177, 224.
- [20] ZHOU M, JIN M. Holographic ensemble forecasting method for short-term power load[J]. IEEE Transactions on Smart Grid, 2019, 10(1):425-434.
- [21] OUYANG T, HE Y, LI H, et al. Modeling and forecasting short-term power load with copula model and deep belief network[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2019, 3(2):127-136.
- [22] 潘广旭,宫池玉,李兴玉,等. 基于开发智慧云平台的日前建筑用电负荷预测方法研究[J]. 电气传动, 2022, 52(12):47-53.
- PAN Guangxu, GONG Chiyu, LI Xingyu, et al. Research on day-ahead forecasting method of building electricity load based on the development of smart cloud platform[J]. Electric Drive, 2022, 52(12):47-53.

收稿日期:2022-05-21

修改稿日期:2022-06-30