

基于多尺度权重适配和双向门控循环单元的工业 企业短期电力负荷预测方法

江 山,李 卫,汤子琪
(阳光电源(上海)有限公司,上海 201100)

摘要:工业企业历史用电负荷数据具有波动性强与时序性复杂的特点,为准确预测用电负荷带来了一定的挑战。针对此问题,提出一种基于多尺度权重适配和双向门控循环单元(multi scale weight adaptation and bidirectional gated recurrent unit,MSWA-BiGRU)的工业企业短期负荷预测方法。模型由权重适配层、BiGRU层、特征嵌入层与全连接预测层组成。首先,利用权重适配层自适应生成对不同时间尺度负荷数据的依赖热力系数进行加权,然后基于BiGRU层同时学习历史负荷序列多尺度上的瞬态波动性特征与稳态周期性特征,再利用特征嵌入层对其他特征进行建模,最终将时序特征与其他特征融合,由全连接预测层获得最终负荷预测结果。通过真实用电负荷数据进行案例分析,结果表明,所提出方法的预测性能优于其他方法,验证了该方法的有效性与其可行性。

关键词:短期负荷预测;多尺度特征;权重适配;双向门控循环单元;特征嵌入;工业企业

Short-term power load forecasting method for industry based on multi scale weight adaptation and bidirectional gated recurrent unit

JIANG Shan, LI Wei, TANG Ziqi
(Sungrow Power (Shanghai) Co., Ltd., Shanghai 201100, China)

Abstract: Historical electricity load data of industrial enterprises has the characteristics of strong volatility and complex sequence, which brings challenges for accurately predicting electricity load. In order to solve these problems, a short-term load forecasting method for industry based on multi scale weight adaptation and bidirectional gated recurrent unit (MSWA BiGRU) is proposed. The proposed model is composed by a weight adaptation layer, a BiGRU layer, a feature embedding layer, and a fully connected prediction layer. Firstly, the weight adaptation layer adaptively generates the dependent thermal coefficients for different time scale load data, and then the BiGRU layer simultaneously learns the transient fluctuation characteristics and steady-state periodic characteristics of the historical load series on multiple scales. Then, other features is embedded in the feature embedding layer. Finally, the temporal features are fused with other features to obtain the final load prediction result through the fully connected prediction layer. Experimental results on real data of electricity load in industrial and commercial enterprises show that the prediction performance of the proposed method is superior to other methods, thus the effectiveness and feasibility of this method are verified.

Key words: short term load forecasting; multi scale features; weight adaptation; bidirectional gated recurrent unit; feature embedding; industry enterprises

0 引言

随着我国电力市场化改革的深入推进,大型工业用户将实现直接面向电力市场参与交易^[1]。对未来生产用电负荷的准确预测既可以保证企业充沛的能量供给,也能够节约企业的生产成本,与此同时也是提供给供电部门进行资源调度、生产规划的有效抓手^[2]。基于此,对工业企业短期负荷预测性

能提出了更高的要求。

负荷预测技术的核心在于预测模型,现有的预测模型大致可分为以下3种类型:基于时间序列分析的预测模型、基于机器学习的预测模型和基于深度学习的预测模型。

基于时间序列分析的预测模型主要围绕时序处理技术展开。文献[3]的采用了卡尔曼滤波(Kalman Filter)与相空间重构组合的方式预测负荷;文献[4]对小波变换后的负荷序列进行差分自回归移动平均模型(autoregressive integrated moving average model, ARIMA)预测,降低序列噪声。这类模型原

收稿日期:2025-05-21;修回日期:2025-08-16

基金项目:上海市促进产业高质量发展专项(人工智能专题)
(2021-GZL-RGZN-01005)

理简单,运行速度快,具有一定的时序信息学习能力。但是无法有效刻画复杂序列的波动性与不确定性,且仅利用负荷序列本身,忽略了其他相关特征的影响,对信息的提取能力有限。

基于机器学习的预测模型对负荷序列以及其他特征(如天气、时间戳信息等)进行数据挖掘,以实现负荷预测^[5-7]。文献[8]提出了一种基于支持向量回归(support vector regression, SVR)的电力负荷预测算法,综合学习时序以及其他特征;文献[9—11]采用基于梯度提升树(gradient boosting regression tree, GBRT)获取预测模型的全局最优解,提高了预测精度。该类方法对负荷序列中的非线性与波动性有较好的学习能力,但其特征处理技术仍难以有效刻画复杂电力系统。

基于深度学习的预测模型对数据特征强有力的捕捉能力,因此越来越深入应用于工业场景中^[12-13]。文献[14—16]提出了基于长短期记忆(long short-term memory, LSTM)网络的负荷预测算法,利用LSTM刻画历史负荷的时序特征。门控循环单元(gated recurrent unit, GRU)将LSTM的输入门与遗忘门进行整合,提高了运算效率,更利于模型收敛。文献[17]利用独热编码融合离散特征,利用GRU学习时序波动特征;文献[18]提出了基于双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的负荷预测模型。该类方法对序列的时序性与波动性有较强的刻画能力,但目前该方法对负荷预测的研究与应用多集中于对单一时间尺度序列的学习,鲜有考虑不同时间尺度序列中包含的复杂时序信息,并且现有方法大多忽略了不同时间步对于预测结果的影响权重差异,该类方法还存在较大的优化空间。

工业企业用电与生产活动强相关,由于其生产计划、生产班期等变化会导致用电负荷波动复杂,其用电负荷曲线会在不同阶段、不同时间尺度上呈现出不同的波动规律,这些特点都给工业企业短期负荷预测准确度带来了挑战。针对工业企业负荷预测的难点以及研究不足的现状,本文提出了一种基于多尺度权重适配和双向门控循环单元(multi scale weight adaptation and bidirectional gated recurrent unit, MSWA-BiGRU)的工业企业短期负荷预测方法。首先,通过权重适配层建模多尺度历史时序数据中不同历史时刻对当前时刻的影响权重,更深入充分的挖掘历史信息,同时,本文还构建了特征嵌入层用以建模其他特征(如是否假期、周末等),最终将时序特征与其他特征融合后传入预测层得到负荷预测结果。相比于其他方法,本文提出的建

模方式更符合工业企业实际生产情况,可解释性强,增强了对不同时间尺度时序特征的捕捉与刻画能力,同时兼顾了其他特征的影响。通过某服装纺织企业实际用电负荷数据的算例验证,与主流方法相比,所提出方法的预测性能有明显提升。

1 GRU模型原理

GRU是循环神经网络(recurrent neural network, RNN)的一种,是为了解决时间序列长期记忆依赖以及反向传播过程中的梯度消失问题而提出的^[19]。相比于长短时记忆网络(long short-term memory, LSTM),GRU在其基础上整合输入门与遗忘门形成了更新门。结构上的优化使得GRU在保留LSTM优良性能的基础上,减少了模型参数,提高了运算速率。GRU具体结构如图1所示,包含重置门与更新门。其中,重置门用于控制对前一状态的遗忘程度,更新门则决定对记忆信息的保留程度,通过状态记忆与多层链式递归的方式实现对时序特征的建模。




图1 GRU结构

Fig. 1 GRU framework

GRU的计算方式如下

$$\begin{cases} r_t = \sigma(W_{rx}x_t + h_{t-1}W_{rh} + b_r) \\ z_t = \sigma(W_{zx}x_t + h_{t-1}W_{zh} + b_z) \\ \hat{h}_t = \tanh(W_{hx}x_t + r_t \odot h_{t-1}W_{hh} + b_h) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \hat{h}_t \end{cases} \quad (1)$$

式中: x_t 为 t 时刻输入向量; r_t 为 t 时刻重置门输出向量; h_t 为 t 时刻输出状态向量; z_t 为 t 时刻更新门的输出向量; W_{rx} 、 W_{rh} 、 W_{zx} 、 W_{zh} 、 W_{hx} 、 W_{hh} 均为权重矩阵; b_r 、 b_z 、 b_h 为偏置项; $\odot$ 为矩阵点乘运算; σ 是Sigmoid激活函数,其作用是将 r_t 与 z_t 归一化至区间 $[0, 1]$; $\tanh$ 为tanh激活函数,其作用为将输出结果限制于区间 $[-1, 1]$ 上。

2 MSWA-BiGRU预测模型

短期负荷预测任务一般为利用历史负荷序列预测下一时刻的负荷值。因此,对历史负荷序列的

建模质量直接影响模型的预测性能。

为有效刻画历史负荷序列中蕴含的信息以提高负荷预测模型的性能,本文构建了多尺度权重适配和双向门控循环单元(MSWA-BiGRU)的负荷预测模型。其核心思想是实现了对多尺度负荷序列的学习,以尽可能挖掘负荷在不同尺度上的变化模式。在本文所提模型中,设计了权重适配层以刻画不同历史时刻的差异性,对多尺度时序信息进行了有效融合;通过BiGRU模块学习不同时间尺度上负荷序列的时序特征,深入交叉以充分挖掘隐含特征;设计了特征嵌入层融合其他特征,将离散特征连续化,构造为更利于神经网络模型学习的向量化数据;最后通过全连接预测层获取负荷预测结果。本文所提出预测模型的框架结构如图2所示。




图2 MSWA-BiGRU框架结构

Fig. 2 Framework of MSWA-BiGRU

2.1 数据预处理

数据预处理过程包含异常值处理与数据归一化。数据中的异常值一般由数据采集设备故障或人为操作失误造成,本文采用均值插补法进行填充。

完成对数据中的异常值清洗与处理后,对数据进行归一化操作。数据归一化缓解了不同特征在数据量级上的差异,有利于神经网络模型的寻优与收敛。本文采用极值归一化法,其公式如下

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

式中: x' 为原始数据 x 经过归一化后的结果; $x_{\min}$ 与 $x_{\max}$ 分别为历史负荷序列中的最小值与最大值。

通过MSWA-BiGRU获得的预测结果,需根据式(2)的计算方式进行反归一化处理,得到实际负荷预测值。

2.2 权重适配层

在实际工业生产中,工作计划的改变往往会引

起生产计划的变动,由此使得用电模式出现差异。同时,考虑历史时刻距当前时刻的远近程度以及历史负荷序列中蕴含的波动性与周期性规律,当前时刻对不同历史时刻的依赖相关度具有差异性。模型引入此类差异性信息,更符合实际工业生产中的特点。本文设计了权重适配层自适应学习不同时刻的依赖权重,其内部结构如图3所示。




图3 权重适配层网络结构

Fig. 3 Framework of weight adaptation layer

原始数据经过全连接层的特征交叉与知识蒸馏,输入softmax层,softmax层的数据计算公式如下

$$\omega_i = \frac{e^{v_i}}{\sum_{j=t-1}^T e^{v_j}} \quad (3)$$

式中: ω_i 为历史时刻 i 的权重; v_i 为历史时刻 i 的输入数据; v_j 为历史时刻 j 的输入数据; t 为当前时刻; T 为历史序列总时刻; e 为自然对数底。

2.3 BiGRU 层

GRU 具有学习时序数据中时间依赖关系的能力,但其仅能基于往期历史数据学习时间尺度上前向传播的信息。在负荷预测领域中,负荷数据具有连续性的特点,相邻的前后时刻负荷波动趋势具有相关度。为深入挖掘负荷的时序特性,本文采用BiGRU学习负荷序列的双向传播信息。BiGRU的结构如图4所示。




图4 BiGRU网络结构

Fig. 4 Framework of BiGRU

BiGRU在刻画时序信息时,同时对时间序列的

前向传播过程与后向传播过程进行编码,最终的输出向量中既包含了前向信息也包含了后向信息,对时序信息的学习更为全面充分。

2.4 特征嵌入层

特征嵌入(embedding)表征,也可被称为特征表示学习,最初被用于自然语言处理领域对字词实体进行建模^[20]。特征嵌入的主要目标是将现实世界中的具体实体或类别属性映射到神经网络模型的向量中,能够进行训练与参数更新,其公式表达如下

$$v_k = f_{\text{embedding}}(u_k), k \in C \quad (4)$$

式中: u_k 为特征 u 的第 k 种类型; C 为特征 u 所有类型的集合; v_k 为对应输出的嵌入向量; $f_{\text{embedding}}$ 为编码函数,常见的编码方式有独热编码、随机初始化 Embedding 矩阵编码等方式,本文采用随机初始化 Embedding 矩阵编码的方式。

2.5 全连接预测层

全连接预测层作为整个模型的最后单元,整合特征提取单元获得的信息,实现最终的负荷预测,其结构如图5所示。




图5 预测层网络结构

Fig. 5 Framework of prediction layer

预测层由多个全连接层堆叠而成,对知识信息进行深入交叉与蒸馏,同时设置 Dropout 操作与 Batchnormalization 操作避免神经元的过拟合与梯度消失,最终的激活函数采用 Relu 函数。Relu 函数的计算公式如下

$$R(z) = \max(0, z) \quad (5)$$

式中: z 为输入数据; $R(z)$ 为函数输出数据。Relu 由于其梯度不会收敛到 0,因此在神经网络梯度反向传播过程中能够有效缓解梯度消失的现象。

综合上述部分,MSWA-BiGRU 负荷预测计算流程如图6所示。




图6 MSWA-BiGRU 负荷预测流程

Fig. 6 Load forecasting process of MSWA-BiGRU

3 实例分析

3.1 数据集与评价指标

本文采集某服装纺织企业 2020 年 5 月至 2021 年 12 月的用电负荷数据作为数据集,采样间隔为 5 min,单日采集 288 个点。开展实验时,以 2020 年 5 月至 2021 年 11 月的数据作为训练集,以 2021 年 12 月的数据作为测试集。模型输入特征为:时刻尺度历史负荷(近 24 h 负荷),日尺度历史负荷(近 7 d 负荷),预测日时间信息(是否为假期、日期周内位置、日期月度位置以及月度信息)。

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)评价预测结果的偏离度,相关系数(correlation coefficient, corr)评价预测结果的趋势相似度,评价指标公式如下

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (6)$$

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

$$c_{\text{orr}} = \frac{\text{cov}(\hat{y} - y)}{\sqrt{\text{var}(\hat{y})} \sqrt{\text{var}(y)}} \quad (8)$$

式中: n 为样本总数; y_i 与 $\hat{y}_i$ 分别为预测日期的真实值与预测值; cov 为协方差运算; var 为方差运算。

3.2 实验结果分析

实验中,MSWA-BiGRU 的模型参数如表 1 所示。

3.2.1 多尺度权重适配层依赖热力图

本实验中 MSWA-BiGRU 模型学习多尺度历史负荷序列中蕴含的信息,包含时刻负荷尺度数据以及日负荷尺度数据。通过对时刻尺度与日尺度负荷数据的挖掘,模型能够有效刻画历史负荷的瞬态波动特征与稳态周期特征。同时,在实际生产场景

表1 MSWA-BiGRU 参数设置
Table 1 Parameter settings of MSWA-BiGRU

参数	取值
日尺度BiGRU单元数量/个	64
日尺度BiGRU层数/层	3
时刻尺度BiGRU单元数量/个	16
时刻尺度BiGRU层数/层	3
嵌入层神经元数量/个	8
全连接层神经元数量/个	64

下,由于生产计划变动或其他因素影响,不同历史时刻或不同历史日期对当前用电负荷的相关度存在差异性。MSWA-BiGRU中的权重适配层将这种差异性抽象为对不同历史时刻或时期的依赖权重,图7、图8分别展示了本实验对时刻尺度负荷序列与日尺度负荷序列的依赖权重热力图(明暗程度代表权重大小)。由图7、图8可知,模型对不同历史时刻或历史时期的依赖权重有较大差异,这种差异蕴含了历史时刻或日期远近对当前时间的相关程度以及生产任务或生产制度的变化波动。权重适配层自适应地基于历史数据分配依赖权重,刻画了不同时刻或时期对预测结果影响的差异性,以实现更准确的负荷预测结果。




图7 时刻尺度权重依赖热力图
Fig. 7 Heat map of time scale weights




图8 日尺度权重依赖热力图
Fig. 8 Heat map of daily scale weights

3.2.2 负荷预测结果对比

为了验证本文所提出方法(MSWA-BiGRU)的有效性,将本文提出方法与SVR、GBRT、BiGRU-single scale、BiGRU-multi scale等方法进行对比实验。其中,SVR模型基于原始特征构造支持向量以寻优最佳分隔超平面;GBRT基于决策回归树对原始特征进行优选融合实现回归;BiGRU-single scale为仅利用单尺度时序信息的BiGRU模型;BiGRU-multi scale为利用多尺度时序信息的BiGRU模型;本文所提出方法(MSWA-BiGRU)引入了多尺度时序信息与不同历史时间的权重适配策略。

表2展示了不同模型的负荷预测性能指标结果。从表2的实验结果看,本文提出的MSWA-BiGRU的预测结果在各项指标表现上均优于其他方法。对比方法中,SVR与GBRT属于基于机器学习的模型,SVR构造支持向量或GBRT决策树特征交叉的方式对特征的刻画能力有限,无法挖掘深层隐含特征;BiGRU系列的模型属于基于神经网络的模型,得益于BiGRU以及神经网络强大的特征交叉与非线性拟合能力,其预测性能大都表现更优;BiGRU-single scale仅利用了单尺度时序信息,BiGRU-multi scale利用了多尺度时序信息,对时序信息的挖掘更为全面,二者对比,验证了采用多尺度时序信息的有效性;与BiGRU-multi scale相比,MSWA-BiGRU在引入多尺度时序信息的基础上,还加入了基于权重适配的多尺度时序信息融合策略,并考虑了不同历史时刻的影响差异性,其预测性能也证明了本文提出方案的有效性。

表2 模型预测性能指标对比
Table 2 Comparison of prediction performance indicators

模型	R_{MSE}/kW	$M_{APE}/\%$	c_{err}
SVR	8.70	6.14	0.801
GBRT	8.17	6.89	0.962
BiGRU-single scale	8.29	6.12	0.898
BiGRU-multi scale	7.04	5.80	0.970
MSWA-BiGRU	5.05	3.83	0.982

图9展示了2021年12月10日的负荷预测结果曲线,从图9可见,MSWA-BiGRU的预测负荷曲线相较于其他方法与真实负荷曲线更为贴合,对于负荷序列的趋势变化与波动拟合度更优。




图9 各模型预测曲线

Fig. 9 Prediction curves of each model

3.2.3 预测泛化性与稳定性实验验证

为进一步验证本文所提出方法在不同时期的泛化能力与稳定性,选取不同时间段进行验证。在全年的每个季度内选取了数据质量达标的月份进行了实验,分别为3月(一季度)、5月(二季度)、7月(三季度)以及12月(四季度),预测结果如表3。

表3 典型月份模型预测性能指标对比

Table 3 Comparison of prediction performance indicators in typical month

典型月份	模型	R_{MSE}/kW	$M_{APE}/\%$	c_{err}
3月	SVR	10.25	5.58	0.571
	GBRT	8.31	4.15	0.906
	BiGRU-single scale	9.81	5.17	0.620
	BiGRU-multi scale	5.61	2.57	0.852
	MSWA-BiGRU	4.85	2.26	0.917
5月	SVR	7.73	4.01	0.895
	GBRT	6.30	3.11	0.916
	BiGRU-single scale	5.85	2.80	0.891
	BiGRU-multi scale	5.55	2.67	0.919
	MSWA-BiGRU	4.96	2.39	0.923
7月	SVR	15.39	12.35	0.701
	GBRT	11.97	10.38	0.920
	BiGRU-single scale	9.63	5.76	0.895
	BiGRU-multi scale	9.82	5.56	0.961
	MSWA-BiGRU	7.81	4.75	0.968

由表3可知,在不同月份中,对比不同方法,本文提出的MSWA-BiGRU均取得了最优的预测性能,验证了本文所提出方法的泛化能力与稳定性。

4 结束语

针对工业企业用电情况复杂、受生产计划影响大、历史负荷数据具有强波动性与复杂时序性的特点导致负荷预测效果受影响的问题,本文提出了一种基于MSWA-BiGRU的工业企业短期负荷预测方法。首先,通过权重适配层动态学习模型对多尺度时间序列中不同历史时刻的依赖权重,然后基于BiGRU模块捕捉多尺度时间序列的瞬态波动性特征与稳态周期性特征,同时利用特征嵌入层用以建模其他特征(如是否假期、周末等),最终将时序特征与其他特征融合后进行负荷预测。本文利用真实工业企业用电数据对所提出方法进行对比验证,得出如下结论:

(1) 通过学习多时间尺度的历史负荷序列,为预测模型提供了更多的先验知识,充分挖掘历史负荷的时序信息。

(2) 设计了权重适配层,能够有效建模历史数据中不同时刻对预测时刻的影响权重,更符合工业企业受不同历史时期生产计划变动而带来用电负荷模式波动的特点,建模的可解释性更强,有助于预测准确度的提升。

(3) 利用BiGRU能够更有效地挖掘工业企业用电负荷序列“双向”推演中蕴含的信息,有助于预测准确度的提升。

(4) 实验结果表明,本文提出方法的预测性能优于其他方法,验证了本文方法的有效性。D

参考文献:

- [1] 杨德州,刘嘉明,宋汶秦,等. 基于改进型自适应白噪声完备集成经验模态分解的工业用户负荷预测方法[J]. 电力系统保护与控制, 2022, 50(4): 36-43.
YANG Dezhou, LIU Jiaming, SONG Wenqin, et al. A load forecasting method for industrial customers based on the ICEEMDAN algorithm[J]. System Protection and Control, 2022, 50(4): 36-43.
- [2] 赵龙,杨波,卢志鹏,等. 基于谱聚类和AM-LSTM的分布式光伏集群超短期预测方法[J]. 供用电, 2023, 40(7): 10-17.
ZHAO Long, YANG Bo, LU Zhipeng, et al. Ultra-short-term cluster distributed photovoltaic power prediction method based on spectral clustering and AM-LSTM[J]. Distribution & Utilization, 2023, 40(7): 10-17.
- [3] 付文杰,李化,杨伯青,等. 基于集合卡尔曼滤波与相空间重构的负荷预测方法研究[J]. 电力需求侧管理,

- 2022, 24(1):49-54.
- FU Wenjie, LI Hua, YANG Boqing, et al. Research of load forecasting method based on ensemble Kalman filter and phase-space reconstruction[J]. Power Demand Side Management, 2022, 24(1):51-57.
- [4] CHE J, ZHAI H. WT-ARIMA combination modelling for short-term load forecasting[J]. IAENG International Journal of Computer Science, 2022, 49(2):542-548.
- [5] 彭维珂, 聂椿明, 陈衡, 等. 基于智能算法的空冷火电机负荷预测研究[J]. 华电技术, 2021, 43(3):57-64.
- PENG Weike, NIE Chunming, CHEN Heng, et al. Study on load forecasting for air cooling thermal power units based on intelligent algorithm[J]. Huadian Technology Intelligent Energy, 2021, 43(3):57-64.
- [6] 俞胜, 黄福兴, 冯艳丽, 等. 新型电力AMI系统中基于Neural Prophet模型的电力负荷预测与修补研究[J]. 智慧电力, 2023, 51(5):44-50.
- YU Sheng, HUANG Fuxing, FENG Yanli, et al. Neural prophet-based power load forecasting and repair in novel power AMI system[J]. Smart Power, 2023, 51(5):44-50.
- [7] 江梦洋. 基于相关向量机的电力系统月度负荷预测[D]. 上海: 上海交通大学, 2016.
- JIANG Mengyang. Research on grid monthly load forecasting based on relevance vector machine[D]. Shanghai: Shanghai Jiao Tong University, 2016.
- [8] ZHANG W, GU L, SHI Y, et al. A hybrid SVR with the firefly algorithm enhanced by a logarithmic spiral for electric load forecasting[J]. Frontiers in Energy Research, 2022, 10:977-984.
- [9] 王鸿斌, 武进军, 吴旭, 等. 基于梯度提升树的写字楼月度用电量预测研究[J]. 电力科学与工程, 2021, 37(4):30-36.
- WANG Hongbin, WU Jinjun, WU Xu, et al. Research on monthly electricity consumption prediction of office buildings based on gradient lifting tree[J]. Electric Power Science and Engineering, 2021, 37(4):30-36.
- [10] GAO Z, YIN X, ZHAO F, et al. A two-layer SSA-XGBoost-MLR continuous multi-day peak load forecasting method based on hybrid aggregated two-phase decomposition[J]. Energy Reports, 2022, 8:12 426-12 441.
- [11] WANG S, WANG D. Combined probability density model for medium term load forecasting based on quantile regression and kernel density estimation[J]. Energy Procedia, 2019, 158:6 446-6 451.
- [12] 孙辉, 杨帆, 高正男, 等. 考虑特征重要性值波动的MI-BILSTM短期负荷预测[J]. 电力系统自动化, 2022, 46(8):9.
- SUN Hui, YANG Fan, GAO Zhengnan, et al. Short-term load forecasting based on mutual information and bi-directional long short-term memory network considering fluctuation in importance values of features[J]. Automation of Electric Power Systems, 2022, 46(8):9.
- [13] ZAMBRANO-ASANZA S, MORALES R E, MONTALVAN J A, et al. Integrating artificial neural networks and cellular automata model for spatial-temporal load forecasting[J]. International Journal of Electrical Power & Energy Systems, 2023, 148:108 906.
- [14] ZHENG H, YUAN J, CHEN L. Short-term load forecasting using EMD-LSTM neural networks with a Xgboost algorithm for feature importance evaluation[J]. Energies, 2017, 10(8):1 168.
- [15] STRATIGKOS A, BACHOUMIS A, VITA V, et al. Short-term net load forecasting with singular spectrum analysis and LSTM neural networks[J]. Energies, 2021, 14(14):4 107.
- [16] BOUKTIF S, FIAZ A, OUNI A, et al. Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting[J]. Energies, 2020, 13(2):391.
- [17] 吴福疆, 范晟, 王振达, 等. 基于门控递归神经网络的电网日峰值负荷预测[J]. 计算技术与自动化, 2020, 39(4):20-26, 56.
- WU Fujiang, FAN Sheng, WANG Zhenda, et al. Daily peak load forecasting based on gating recurrent neural network[J]. Computing Technology and Automation, 2020, 39(4):20-26, 56.
- [18] NIU D, YU M, SUN L, et al. Short-term multi-energy load forecasting for integrated energy systems based on CNN-BiGRU optimized by attention mechanism[J]. Applied Energy, 2022, 313:118 801.
- [19] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. Computer Science, 2014. DOI:10.3115/v1/D14-1179.
- [20] 张子静. 基于向量空间映射的知识嵌入表征[D]. 成都: 电子科技大学, 2023.
- ZHANG Zijing. Knowledge embedding representation based on vector space mapping[D]. Chengdu: University of Electronic Science and Technology of China, 2023.

作者简介:

江山(1996),男,江苏南京人,硕士,工程师,主要从事新能源预测、新能源调度管理等方面工作。

李卫(1979),男,通信作者,安徽安庆人,博士,高级工程师,研究方向为新能源发电系统智能化技术;

汤子琪(1992),女,江苏扬州人,硕士,工程师,主要从事新能源资源评估与预测工作。

(责任编辑 水 鸪)