

基于 LASSO 和 LSTM-GRU 的综合能源系统 负荷预测

赵发金,舒征宇,王灿,刘文灿,黄启昀

(三峡大学 电气与新能源学院,湖北 宜昌 443002)

摘要:精确高效的多元负荷预测对于综合能源系统的运行控制与调度具有重要意义,为了改善负荷预测效果,提出了一种基于压缩估计(LASSO)和LSTM-GRU神经网络的综合能源系统负荷预测模型。首先,针对综合能源系统气象因素导致数据复杂的问题,研究了基于LASSO回归的大数据选择及分析算法,对气象因数选择分析,获得有效的数据集;其次,采用长短期记忆(LSTM)神经网络对系统负荷进行预测,得到初步预测值;随后,采用门控循环单元(GRU)构建误差补偿模型,通过对预测误差的训练与学习,得到预测误差的补偿值;最后通过重构二者的输出,得到更理想的预测结果。通过算例仿真验证,所构建的预测模型相比于传统的LSTM神经网络预测模型与粒子群算法(PSO)优化的LSTM预测模型,具有更高的预测精确度。

关键词:负荷预测;综合能源系统;LASSO回归;误差补偿;LSTM神经网络

中图分类号:TM715 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd25820

Integrated Energy System Load Forecasting Based on LASSO and LSTM-GRU

ZHAO Fajin, SHU Zhengyu, WANG Can, LIU Wencan, HUANG Qiyun

(College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, Hubei, China)

Abstract: Accurate and efficient multi-load forecasting is of great significance for the operation control and scheduling of integrated energy system (IES), in order to improve the load forecasting effect, a integrated energy system load prediction model based on least absolute shrinkage and selection operator (LASSO) and LSTM-GRU neural network was proposed. Firstly, in order to solve the problem of complex data caused by meteorological factors in the integrated energy system, a big data selection and analysis algorithm based on LASSO was studied to select and analyze the meteorological factors to obtain an effective data set. Secondly, the long short-term memory (LSTM) neural network was used to predict the system load, and the preliminary prediction value was obtained. Subsequently, the gated recurrent unit (GRU) was used to construct the error compensation model, and the compensation value of the prediction error was obtained through the training and learning of the prediction error. Finally, by reconstructing the output of the two, a more ideal prediction result was obtained. Through the simulation of the example, the proposed prediction model has higher prediction accuracy than the traditional LSTM neural network prediction model and the LSTM model optimized by particle swarm optimizer(PSO).

Key words: load forecasting; integrated energy system (IES); LASSO algorithm; error compensation; long short-term memory (LSTM) neural network

随着我国经济快速发展,能源短缺问题与环境保护压力与日俱增,为了缓解能源危机,实现多种资源的整合与高效利用,综合能源系统(integrated energy system, IES)成为了能源行业研究的热点^[1]。IES以电力系统为核心,考虑了电、热

等多种负荷之间的耦合关系,通过协调不同能源在同一区域内的应用,有效地提高了能源利用率,因此,对IES进行科学合理的负荷预测具有重要意义^[2]。

精确高效的多元负荷短期预测对于 IES 的

基金项目:国家自然科学基金(52107108)

作者简介:赵发金(1999—),男,硕士研究生,研究方向为综合能源系统预测与调度,Email:2946595258@qq.com

通讯作者:舒征宇(1983—),男,博士,副教授,研究方向为含新能源的电力系统优化规划、智能电网运维,Email:18702031@qq.com

运行控制与调度具有重要意义^[3]。首先,通过预测结果对各种能源进行合理调配,能够显著提升 IES 的经济性^[4];其次,根据预测结果进行系统需求侧分析,并制定响应计划,可以有效提升 IES 的运行可靠性^[5]。现有的预测方法大多数都是针对单一负荷类型的预测^[6]。在文献[7]中,研究人员利用主成分分析法对模态向量降维后通过深度双向长短期记忆神经网络进行负荷预测;文献[8]提出一种基于 BiLSTM 的负荷预测模型,通过学习对负荷预测起到关键因素的输入特征,可以得到更准确的预测结果。

但是仅针对多元负荷中某一种负荷进行单独预测,其精度往往有限,如何利用多种能源与负荷之间的耦合关系来提升预测精度是一大研究热点^[9-11]。文献[12]提出一种以 LSTM 神经网络作为共享层的 MTL 多元负荷预测方法,通过共享机制学习不同任务的共享信息,以提升 IES 的多元负荷预测精度。文献[13]构建了基于相关性指标的 GRU 负荷预测模型,通过计算气象因素及负荷之间的相关性来对多元负荷进行预测,验证了多元负荷相比单一的负荷预测具有更高的预测精度。文献[14]将历史负荷数据通过 ALIF 分解为波动序列、周期序列及趋势序列等多个分量后通过长短期记忆神经网络建立负荷预测模型,从数据层面提高了负荷预测精度。上述方法对多元负荷进行预测时,考虑到的气象因素比较局限,会导致关键气象信息丢失。另外,当前对于组合预测模型的研究主要着重于利用一些新颖的算法对神经网络参数进行寻优或者利用机器学习进行数据特征挖掘,少有文献着重于对负荷预测的结果进行误差补偿研究。

基于上述分析,针对影响综合能源系统负荷预测精确度的多种气象因素,本文利用 LASSO 压缩估计回归对多种气象因素进行压缩降维,筛选出与多元负荷具有强相关性的气象特征。提出利用 GRU 神经网络构建误差补偿模型,对 LSTM 神经网络初步预测的误差进行补偿,通过补偿值来消除系统误差,就可以得到更为精确的负荷预测结果。通过算例仿真验证,本文所提预测模型可以取得良好的预测效果。

1 LASSO 变量选择原理

由于 IES 中各种形式的能源与能源之间、负荷与负荷之间具有较强的耦合性,如果单独对其

中某种负荷直接进行预测,预测结果往往不理想,所以在对综合能源系统多元负荷进行预测的过程中,需要考虑各负荷间协调互补的特性。

除了多元负荷之间的耦合关系会影响综合能源系统负荷预测精确度外,其它如气温、光照、湿度等多种气象也会直接影响负荷预测结果,但是并非所有的气象因素都会对预测结果造成很大影响,因此需要对多种气象因素进行分析降维,筛选出与负荷具有强相关性的气象因素。LASSO 回归模型通过对线型回归系数施加约束和惩罚,将某些噪音变量的系数估计值压缩为 0,从而剔除并筛选出重点变量^[15],可以用来筛选对多元负荷预测影响较大的气象因素。

对于一组样本数据 $\{x_{i1}, x_{i2}, \dots, x_{ip}; y_i\}$, 其中 $i=1, 2, \dots, n$, 其对应的回归模型可以表示为

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon \quad (1)$$

式中: α 为常数项; ε 为随机扰动项; $\beta_1, \beta_2, \dots, \beta_p$ 为自变量的回归系数。

引入一个惩罚参数 $s \geq 0$, 式(1)中估计值 $(\hat{\alpha}, \hat{\beta})$ 的 LASSO 定义表达式如下:

$$\begin{cases} (\hat{\alpha}, \hat{\beta}) = \operatorname{argmin} \left\{ \sum_{i=1}^n (y_i - \alpha - \sum_{j=1}^p \beta_j x_{ij})^2 \right\} \\ \text{s.t. } \sum_{j=1}^p \beta_j \leq s \end{cases} \quad (2)$$

令 $\hat{\beta}_i^0$ 为最小二乘得到的回归参数估计值, $s_0 = \sum_i |\hat{\beta}_i^0|$ 。当 $s \geq s_0$ 时, 最优解即为最小二乘解; 当 $s < s_0$ 时, 就会产生压缩, s 越小, 则压缩效果越强, 随着 s 的减小, 使得回归系数变为极小或为 0, 这样对应回归系数为 0 的气象因素因子就被删除, 从而剔除对多元负荷影响较小的气象因素。

2 预测模型结构

2.1 LSTM 神经网络结构

LSTM 神经网络是循环神经网络 (recurrent neural network, RNN) 的一种改进模型, 其具有良好的非线性数据处理能力, 在长时间序列预测问题的处理上具有良好的效果, 非常适合处理 IES 中具有强季节趋势、长时间序列的历史负荷数据, 因此本文将用于 IES 多元负荷的初步预测。

在 RNN 结构的基础上, LSTM 神经网络引入了门控单元来替代 RNN 隐层中的神经元, 通过输入门、遗忘门和输出门的“三门”结构来控制数据的保留与丢失, 其结构如图 1 所示。




图1 LSTM结构示意图

Fig.1 LSTM neuron structure diagram

图1中,LSTM模型神经元的信息传递过程可由下式表示:

$$\begin{cases} f_t = \sigma(W_f \times h_{t-1} + W_{f_i} \times x_t + b_f) \\ i_t = \sigma(W_i \times h_{t-1} + W_{i_i} \times x_t + b_i) \\ \tilde{C}_t = \tanh(W_C \times h_{t-1} + W_{C_i} \times x_t + b_C) \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\ o_t = \sigma(W_o \times h_{t-1} + W_{o_i} \times x_t + b_o) \\ h_t = o_t \odot \tanh(C_t) \end{cases} \quad (3)$$

式中:\$i_t, o_t, f_t\$分别为神经元输入门、输出门与遗忘门的输出信号;\$W_f, b_f\$分别为遗忘门的权重及偏置量;\$h_t\$为\$t\$时刻的隐层状态;\$x_t\$为\$t\$时刻神经元的输入序列;\$W_i, b_i\$分别为输入门的权重及偏置量;\$\tilde{C}_t\$为\$t\$时刻记忆单元候选状态信息;\$W_C, b_C\$分别为记忆单元的权重及偏置量;\$\sigma, \tanh\$分别为sigmoid激活函数与双曲正切激活函数;\$C_t\$为\$t\$时刻记忆单元的状态;\$W_o, b_o\$分别为输出门的权重及偏置量。

2.2 GRU神经网络结构

GRU神经网络是基于LSTM神经网络的一种改进结构,在克服LSTM梯度消失的基础上提高了模型的训练速度,其结构如图2所示。GRU将LSTM中的遗忘门和输出门进行了合并,相比于图1中LSTM的“三门”结构,GRU只保留了重置门和更新门两个门结构,因此GRU的模型结构更加简洁,在预测精度相当时,GRU的训练速度要高于LSTM的训练速度,本文将其用于预测误差的训练,可以有效地降低模型的复杂程度,提升模型的训练速度。

图2中,GRU神经元输出值计算过程如下:

$$\begin{cases} r_t = \sigma(W_r \times [h_{t-1}, x_t]) \\ z_t = \sigma(W_z \times [h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(W_h \times [r_t \odot h_{t-1}, x_t]) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{cases} \quad (4)$$




图2 GRU结构示意图

Fig.2 GRU neuron structure diagram

式中:\$r_t\$为\$t\$时刻重置门的输出值,其值为0时舍弃\$t-1\$时刻神经元的信息;\$z_t\$为\$t\$时刻更新门的输出值,保留\$t-1\$时刻神经元传递的信息量;\$\tilde{h}_t\$为\$t\$时刻的候选隐状态;\$W_r, W_z, W_h\$分别为重置门、更新门、候选隐状态的权重矩阵。

2.3 误差补偿原理

传统的电力系统负荷预测模型的预测精度有待提高,其中一个重要的因素就是:在负荷预测的预测误差中,除了含有随机误差,还有因为模型性能产生的系统误差,后者将测量值偏向同一个方向,有一定的规律性。误差补偿原理就是寻找系统误差的规律,通过构建一个补偿值来消除系统误差,从而提高负荷预测精确度。

为此,本文在对综合能源系统负荷预测过程中引入了误差补偿技术,通过神经网络建立误差补偿模型,对预测误差进行训练和学习,得到误差补偿值,通过这个补偿值来消除系统误差,从而获得更准确的预测结果。基于GRU误差补偿模型的预测方法分以下两个步骤进行:

步骤1:求解预测误差,利用所构建的LSTM误差预测模型对综合能源多元负荷进行初步预测,通过实际值与预测值作差得到待预测点的预测误差。

步骤2:建立误差补偿模型,将步骤1中的预测误差输入到GRU神经网络中,通过GRU网络对预测误差的学习与训练,得到下一个样本的误差预测值,将初步预测值与误差预测值作和,就实现了预测结果的补偿。

2.4 模型结构

基于LASSO和LSTM-GRU的综合能源系统负荷预测模型结构如图3所示,包括数据预处理、LASSO变量选择、LSTM模型负荷预测、GRU模型误差补偿、误差重构5个部分,各部分功能如下:




图3 负荷预测模型结构图

Fig.3 Load forecasting model structure diagram

1)数据预处理:由于输入的各个气象数据与负荷数据之间量纲存在差异,在对模型预测前需要对输入数据进行归一化处理,方便后续模型的预测和训练。

2)LASSO 变量选择:通过 LASSO 回归对气象因素进行筛选分析,选取与多元负荷具有强相关性的气象因素。

3)LSTM 负荷预测:负荷预测层的作用是利用 LSTM 神经网络对样本数据进行学习与训练,得到负荷的初步预测值,并通过初步预测值求取负荷预测误差,作为 GRU 误差补偿层的输入。

4)GRU 误差补偿:误差补偿层通过 GRU 神经网络训练负荷误差,得到负荷的误差预测值,进而求得误差补偿值。

5)误差重构:误差重构层的输入是同一个样本数据的负荷预测值和误差补偿值,该层的作用是将二者之和反归一化处理后输出所提模型的最终负荷预测结果。

模型采用 Adam(adaptive moment estimation)优化算法对参数进行优化,该算法计算效率相比于随机梯度下降法更高,可以更快得出使损失函数最优的参数组合,可以代替随机梯度下降法来更新网络权重^[16]。

模型的损失函数为均方误差函数,即

$$h_{\text{loss}} = \frac{1}{n} \sum_{i=1}^n (C_i - \tilde{C}_i)^2 \quad (5)$$

式中: C_i , $\tilde{C}_i$ 分别为实际负荷、预测负荷; n 为每次训练的个数。

3 算例分析

本文通过 Matlab 仿真平台搭建了综合能源

系统负荷预测模型,从某园区综合能源系统选取 2022 年 1 月 1 日—2022 年 7 月 7 日的负荷及气象数据对本文所提预测方法进行验证,数据点采集间隔为 1 h。取 1 月 1 日—6 月 1 日的数据作为训练集;6 月 2 日—7 月 1 日的数据作为模型的验证集;最后一周的数据作为模型的测试集,并将 7 月 7 日的电、冷负荷预测结果进行可视化分析比较。

利用网格搜索法确定网络的超参数,模型训练次数为 100 次,初始学习率为 0.02,在迭代 50 次后逐步衰减,衰减率为 0.1,隐层与全连接层神经元个数分别为 200 个与 50 个,为了防止过拟合现象,dropout 层参数设置为 0.5。

3.1 LASSO 算法数据选择及处理

收集到的影响综合能源系统负荷的气象因素数据包括太阳方位角 X_1 、相对湿度 X_2 、风向 X_3 、紫外线指数 X_4 、太阳辐射 X_5 、气压 X_6 、可降水量 X_7 、平均气温 X_8 、日出时间 X_9 、风速 X_{10} 、污染指数 X_{11} 及最高温度 X_{12} ,将以上气象因素数据标准化、归一化后通过 LASSO 回归进行特征选择,其选择路径如图 4 所示。

通过交叉验证法^[17]得到惩罚参数 s ,当 $s=0.36$ 时模型取得最优值。从图 4 中可以看出,当 $s=0.36$ 有 8 个气象因子被压缩为 0,只剩下 4 个关键气象因素,分别是太阳辐射 X_5 、可降水量 X_7 、平均气温 X_8 及最高温度 X_{12} 。因此,将以上 4 组气象因素数据以及冷、热负荷数据输入到 LSTM-GRU 神经网络中进行负荷预测。

3.2 不同模型对预测精度的影响

为了比较不同模型对综合能源系统负荷预测精度的影响,本文分别使用 LSTM 神经网络模




图4 LASSO算法气象因素选择路径

型、PSO-LSTM神经网络模型和本文所提模型进行了3组预测对比实验,分别对综合能源系统电负荷与冷负荷进行预测,3种模型的电负荷与冷负荷预测结果如图5和图6所示。




图5 不同预测模型的电负荷预测结果

Fig.5 Electrical load prediction results for different forecasting models




图6 不同预测模型的冷负荷预测结果

为了更加直观地体现各模型预测的准确性,选用平均绝对百分比误差(MAPE)来对3种模型进行评价,其结果如表1所示。

从图5与图6中可以看出,相比LSTM神经网络

与 PSO-LSTM 神经网络,采用本文模型预测得到的预测曲线与实际曲线更加贴近,从表1中可以得知,本文所提的负荷预测模型相比于 LSTM 神经网络与 PSO-LSTM 神经网络,在对电负荷预测时 MAPE 值分别下降了 2.27% 与 1.29%,在对冷负荷预测时 MAPE 值下降了 2.45% 与 1.37%,虽然 3 种模型都可以有效地对综合能源系统多元负荷进行预测,但是本文所提模型在预测精度上有大幅度的提升。

表1 不同模型预测结果对比

Tab.1 Prediction error for different models

模型	负荷类型	MAPE/%
本文模型	电负荷	2.85
	冷负荷	2.96
LSTM 神经网络	电负荷	5.12
	冷负荷	5.41
PSO-LSTM 神经网络	电负荷	4.14
	冷负荷	4.33

3.3 误差补偿对预测精度的影响

为了验证所提 GRU 误差补偿模型对负荷预测结果的影响,进行了两组模型预测对比实验,将含误差补偿与不含误差补偿的电、冷负荷预测效果进行对比,其预测结果如表2所示。

表2 有无误差补偿实验结果对比

Tab.2 Comparison of experimental results with and without error compensation

模型	负荷类型	MAPE/%
含误差补偿	电负荷	2.83
	冷负荷	2.86
无误差补偿	电负荷	4.78
	冷负荷	4.65

含误差补偿与不含误差补偿的电、冷负荷预测结果分别如图7与图8所示。




图7 误差补偿对电负荷预测结果的影响

Fig.7 The influence of error compensation on the electrical load prediction results




图8 误差补偿对冷负荷预测结果的影响

Fig.8 The influence of error compensation on the cooling load prediction results

从表2中可以看出,考虑误差补偿的预测模型的预测精度明显优于不考虑误差补偿的预测模型,相比于不含误差补偿的预测模型,含误差补偿的预测模型在电负荷与冷负荷预测的 $MAPE$ 值上分别降低了1.95%与1.79%。从图7与图8中同样可以看出,考虑误差补偿模型的电负荷与冷负荷预测曲线与实际曲线也更加贴近。

4 结论

本文针对IES多元负荷预测问题,提出了基于LASSO回归与LSTM-GRU算法的组合模型,通过算例仿真验证,得出以下结论。

1) LASSO算法可以有效地对影响综合能源系统负荷的多种气象因素进行分析,并筛选出与负荷具有强相关性的气象因素。

2) 通过对综合能源系统电、冷负荷的预测实验表明,本文所提预测模型可以有效地提高综合能源系统负荷预测精度。

3) 通过误差补偿对预测精度的影响实验表明,考虑误差补偿可以有效提升模型预测精度,本模型中考虑误差补偿对电、冷负荷的预测精度提升分别为1.95%和1.79%。

参考文献

[1] RIFKIN J. The third industrial revolution: how lateral power is transforming energy, the economy, and the world[J]. Civil Engineering, 2012, 82(1): 74-75.

[2] 艾芊,郝然. 多能互补、集成优化能源系统关键技术及挑战[J]. 电力系统自动化, 2018, 42(4): 2-10, 46.

AI Qian, HAO Ran. Key technologies and challenges for multi-energy complementarity and optimization of integrated energy systems[J]. Automation of Electric Power Systems, 2018, 42

(4): 2-10, 46.

[3] WANG X, WANG S, ZHAO Q, et al. A multi-energy load prediction model based on deep multi-task learning and ensemble approach for regional integrated energy systems[J]. International Journal of Electrical Power & Energy Systems, 2021, 126(9): 106583.

[4] 吴晨,姚菁,薛贵元,等. 基于MMoE多任务学习和长短时记忆网络的综合能源系统负荷预测[J]. 电力自动化设备, 2022, 42(7): 33-39.

WU Chen, YAO Jing, XUE Guiyuan, et al. Load forecasting of integrated energy system based on MMoE multi-task learning and LSTM[J]. Electric Power Automation Equipment, 2022, 42(7): 33-39.

[5] TALAAT M, FARAHAT MA, MANSOUR N. et al. Load forecasting based on grasshopper optimization and a multilayer feed-forward neural network using regressive approach[J]. Energy, 2020, 196: 117087.

[6] 朱继忠,董瀚江,李盛林,等. 数据驱动的综合能源系统负荷预测综述[J]. 中国电机工程学报, 2021, 41(23): 7905-7923.

ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923.

[7] 陈锦鹏,胡志坚,陈纬楠,等. 二次模态分解组合DBiLSTM-MLR的综合能源系统负荷预测[J]. 电力系统自动化, 2021, 45(13): 85-94.

CHEN Jinpeng, HU Zhijian, CHEN Weinan, et al. Load prediction of integrated energy system based on combination of quadratic modal decomposition and deep bidirectional long short-term memory and multiple linear regression[J]. Automation of Electric Power Systems, 2021, 45(13): 85-94.

[8] 李晓,卢先领. 基于双重注意力机制和GRU网络的短期负荷预测模型[J]. 计算机工程, 2022, 48(2): 291-296, 305.

LI Xiao, LU Xianling. Method for forecasting short-term power load based on dual-stage attention mechanism and gated recurrent unit network[J]. Computer Engineering, 2022, 48(2): 291-296, 305.

[9] 朱凌建,荀子涵,王裕鑫,等. 基于CNN-BiLSTM的短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4532-4539.

ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM[J]. Power System Technology, 2021, 45(11): 4532-4539.

[10] 蔡鑫祥,撒奥洋,周生奇,等. 基于改进Bagging算法与模糊MP-LSTM融合的短期负荷预测模型[J]. 电气工程学报, 2022, 17(1): 164-170.

CAI Xinxiang, HAN Aoyang, ZHOU Shengqi, et al. Short-term load forecasting model based on improved bagging algorithm and fuzzy MP-LSTM fusion[J]. Journal of Electrical Engineering, 2022, 17(1): 164-170.

[11] 倪建辉,张菁,张昊立,等. 基于时序特征灰度图与多任务学习的综合能源负荷短期预测[J]. 电气工程学报, 2024, 19(2): 186-199.

NI Jianhui, ZHANG Jing, ZHANG Haoli, et al. Short-term pre-

- diction of integrated energy load based on time series feature grayscale map and multi-task learning[J]. Journal of Electrical Engineering, 2024, 19(2): 186-199.
- [12] 孙庆凯,王小君,张义志,等. 基于LSTM和多任务学习的综合能源系统多元负荷预测[J]. 电力系统自动化, 2021, 45(5): 63-70.
- SUN Qingkai, WANG Xiaojun, ZHANG Yizhi, et al. Multiple load prediction of integrated energy system based on long short-term memory and multi-task learning[J]. Automation of Electric Power Systems, 2021, 45(5): 63-70.
- [13] 王琛,王颖,郑涛,等. 基于ResNet-LSTM网络和注意力机制的综合能源系统多元负荷预测[J]. 电工技术学报, 2022, 37(7): 1789-1799.
- WANG Chen, WANG Ying, ZHENG Tao, et al. Multi-energy load forecasting in integrated energy system based on ResNet-LSTM network and attention mechanism[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1789-1799.
- [14] 欧阳静,杨吕,尹康,等. 基于ALIF-LSTM多任务学习的综合能源系统短期负荷预测[J]. 太阳能学报, 2022, 43(9): 499-507.
- OUYANG Jing, YANG LÜ, YIN Kang, et al. Short-term load forecasting method for integrated energy system based on ALIF-LSTM and multi-task learning[J]. Acta Energaie Solaris Sinica, 2022, 43(9): 499-507.
- [15] 张贺,范梦萱. 基于Lasso回归模型的青岛海洋经济和海洋产业分析[J]. 海洋开发与管理, 2022, 39(8): 22-28.
- ZHANG He, FAN Mengxuan. The marine economy and marine industry in Qingdao based on Lasso regression model[J]. Ocean Development and Management, 2022, 39(8): 22-28.
- [16] 顾默,赵兵,陈昊. 基于时间卷积网络与图注意力网络的行业日售电量预测方法[J]. 电网技术, 2022, 46(4): 1287-1296.
- GU Mo, ZHAO Bing, CHEN Hao. Daily electricity sales forecasting by industries based on time convolution network and graph attention network[J]. Power System Technology, 2022, 46(4): 1287-1296.
- [17] 张新生,魏志臻,陈章政,等. 基于LASSO-GWO-KELM的工业碳排放预测方法研究[J]. 环境工程, 2023, 41(10): 141-149.
- ZHANG Xinsheng, WEI Zhizhen, CHEN Zhangzheng, et al. Prediction of industrial carbon emissions in Shaanxi province based on LASSO-GWO-KELM model[J]. Environmental Engineering, 2023, 41(10): 141-149.

收稿日期:2024-04-09

修改稿日期:2024-04-19