

基于BWO优化LSTM参数和超参数的短期电力负荷预测

王云佳¹,马国真¹,夏静¹,彭毓图²,邵华³

(1. 国网河北省电力有限公司 经济技术研究院,石家庄 050000;2. 华北电力大学 经济管理系,河北 保定 071000;3. 河北汇智电力工程设计有限公司,石家庄 050000)

摘要:针对智能电网对电力负荷预测精度的高要求,同时考虑到传统的被优化的长短期记忆网络模型(long short-term memory, LSTM)在短期电力负荷预测结果不稳定的问题,提出一种基于白鲸优化算法(beluga whale optimization, BWO)和LSTM的短期电力负荷预测模型。该模型首先将LSTM的超参数作为白鲸的位置,以历史负荷、日类型、天气因素作为数据集,以LSTM在训练集上的预测误差作为BWO的适应度。然后,利用BWO对最适合训练集的LSTM模型的参数和超参数进行寻优,并根据最优的LSTM模型对某地区的电力负荷数据进行预测分析。研究结果表明,BWO-LSTM预测结果的平均绝对误差百分比和均方根误差更小,预测精度更高,且预测结果更稳定,可作为短期电力负荷预测的可靠工具,可以为电力系统安全稳定运行提供有力支撑。

关键词:短期电力负荷预测;白鲸优化算法;长短期记忆网络模型;平均绝对误差百分比;均方根误差

Short-term power load forecasting based on BWO optimization of LSTM parameters and hyperparameters

WANG Yunjia¹, MA Guozhen¹, XIA Jing¹, PENG Yutu², SHAO Hua³

(1. Economic and Technological Research Institute, State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050000, China;2. Department of Economic Management, North China Electric Power University, Baoding 071000, China;3. Hebei Huizhi Power Engineering Design Co., Ltd., Shijiazhuang 050000, China)

Abstract: A short-term power load forecasting model based on the beluga whale optimization (BWO) algorithm and long short-term memory network (LSTM) is proposed to address the high demand for accuracy in power load forecasting in smart grids, while also considering the instability of traditional optimized LSTM models in short-term power load forecasting. The model first uses the hyperparameters of LSTM as the location of the beluga whale, historical load, day type, and weather factors as the dataset, and the prediction error of LSTM on the training set as the fitness of BWO. Then, BWO is used to optimize the parameters and hyperparameters of the LSTM model that is most suitable for the training set, and predict and analyze the power load data of a certain region based on the optimal LSTM model. The research results indicate that the average absolute error percentage and root mean square error of BWO-LSTM prediction results are smaller, the prediction accuracy is higher, and the prediction results are more stable. It can be used as a reliable tool for short-term power load forecasting and provide strong support for the safe and stable operation of the power system.

Key words: short-term power load forecasting; beluga whale optimization; long short-term memory; mean absolute percentage error; root mean square error

0 引言

电力负荷预测作为电网生产运行的重要组成部分,为电网制定供电、调度和交易计划提供指导,有助于减少能源消耗和提高经济效益。近年来,随着新型电力系统的不断建设,电网逐渐向广泛互联、智能互动、灵活柔性、安全可控方向发展,电网

对电力负荷预测提出了更高的要求,准确的负荷预测变得越来越重要且具有挑战性。

对于短期电力负荷预测的方法,其本质上主要可以分为两种,分别是传统统计分析和机器学习方法。传统统计分析方法有时间序列模型和回归分析,这类方法主要以线性数据序列为基础,对于电力负荷预测仅能考虑到数据的连续性关系,无法对外部因素如气候温度、气候类型、节假日等外部因素进行融合^[1]。机器学习方法有随机森林^[2]、支持向量机^[3]与神经网络算法^[4]等,这类方法能够与复杂的非线性数据拟合性好,鲁棒性强,因而受到广

收稿日期:2025-08-29;修回日期:2025-10-28

基金项目:国网河北省电力有限公司科技项目(HZHT KJXM2023-03);国家自然科学基金地区科学项目基金(72164026)

泛使用。由于电力负荷呈现出明显的非线性、多周期性和时变性特点,单独使用一种预测模型往往难达到理想的预测精度,因此,研究人员提出的各种组合预测方法被广泛应用到电力负荷预测数据问题中^[5]。

目前,深度学习算法已成为主流的预测方式,长短期记忆神经网络(long short-term memory, LSTM)特点突出,擅于处理序列型数据,有效减小负荷预测模型需要的数据量维度,充分挖掘序列型数据间的内在关系,相比于其他的机器学习算法有较高的准确性^[6]。也有其他的预测方法比如卷积神经网络(convolution neural networks, CNN)、Transformer 以及其改进方法如 Informer、Autoformer 等相比于 LSTM 存在着一定的局限性。CNN 不适用于处理时间序列数据,而在处理图形数据时, CNN 则会表现出更好的效果^[7]。另外 Transformer 及其改进方法适用于序列较长且需要捕捉全局依赖关系的任务,在需要高并行处理能力和快速训练的任务中表现优异,特别适合自然语言处理中的机器翻译、文本生成和理解任务^[8-9]。因此 LSTM 在处理电力负荷预测场景中应用更加广泛。

为了解决参数调整困难的问题,大量研究人员通过群体智能优化算法改进 LSTM 模型,包括粒子群优化算法 PSO^[10]、麻雀搜索算法 SSA^[11]、遗传算法 GA^[12]、黑猩猩优化算法 COA^[13]和金豺算法 GJO^[14]和灰狼优化算法 GWO^[15]、鲸鱼优化算法 WOA^[16]等。这些改进方法在解决参数调整困难问题的同时,也提高了负荷预测的精度。

然而,电力负荷预测高精度的需求、LSTM 电力负荷预测不稳定以及参数优化不能跳出局部最优的问题一直困扰着研究者们,因此,本文提出一种基于白鲸优化算法改进 LSTM 的短期电力负荷预测模型。该模型通过结合新型优化算法 BWO 可靠的鲁棒性^[17]和 LSTM 优秀的学习能力来提高短期电力负荷预测的精度。

1 基于 BWO-LSTM 的负荷预测模型

1.1 长短期记忆网络模型

长短期记忆网络是一种比较特殊的循环神经网络(recurrent neural network, RNN)。通过对 RNN 的每一个信息状态中都引入 3 个“门控单元”,控制信息是否被保留、是否被遗忘以及是否被输出,由此可以让模型记住之前比较久远但是对于当前时刻的输出又比较重要的信息,同时避免了无用信息的干扰。LSTM 的 4 个交互层如图 1 所示。




图1 LSTM 的4个交互层

Fig. 1 Four interaction layers of LSTM

在图 1 中,每条箭线都代表一个向量,从某个输出节点到另外的输入节点。

(1) 隐藏层

在 LSTM 的隐藏层中,每个时间节点都会接收新的信息输入和前一时间节点的信息输出。

(2) 遗忘门

在这一个遗忘门中,控制了上一层的信息是否应该被遗忘。遗忘门的公式为

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

式中: w_f 为遗忘门权重矩阵; b_f 为偏置项; h_{t-1} 为上一时刻的隐藏状态; x_t 为当前输入; σ 为 sigmoid 函数。

(3) 输入门

在这一个控制门决定哪些新的信息需要被保存到记忆细胞中。输入门公式为

候选值

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (2)$$

输入门值

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

式中: w_c 、 w_i 分别为单元状态更新权重矩阵和输入门权重矩阵; b_c 、 b_i 为偏置项; h_{t-1} 为上一时刻的隐藏状态; x_t 为当前输入; σ 为 sigmoid 函数; $\tanh$ 为双曲正切函数。

(4) 更新记忆细胞

这一阶段需要根据遗忘门的值和输入门的值更新。更新后的细胞状态公式为

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (4)$$

式中: f_t 为遗忘门的输出; C_{t-1} 为上一时刻的细胞状态; i_t 为输入门值; $\tilde{C}_t$ 为候选值。

(5) 输出门和隐藏状态

这一控制门决定将输出什么。输出门公式为

$$O_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

式中: w_o 为输出门权重矩阵; b_o 为偏置项; h_{t-1} 为上一时刻的隐藏状态; x_t 为当前输入; O_t 为 sigmoid 函数; C_t 为当前的细胞状态; $\tanh$ 为双曲正切函数。

1.2 白鲸优化算法

白鲸优化算法是一种新的启发式群智能优化算法,主要包括勘探、开发与鲸落3个的计算步骤。从勘探到开发的过渡,主要通过平衡因子 B_f 来实现,计算公式为

$$B_f = B_0 \left(1 - \frac{t}{2T}\right) \quad (7)$$

式中: t 为当前迭代次数; T 为总迭代次数; B_0 为一个 $(0,1)$ 范围内的随机值,每次迭代过程中该参数值都会变化。

(1) 勘探阶段

勘探阶段是白鲸社会性活动的体现,比如两只白鲸以同步或镜像的方式游泳或觅食,这时白鲸的位置为

$$\begin{cases} x_{ij}^{t+1} = (x_{r,p}^t - x_{i,p}^t)(1 + r_1)\sin(2\pi r_2) & j \text{ 为偶数} \\ x_{ij}^{t+1} = (x_{r,p}^t - x_{i,p}^t)(1 + r_1)\cos(2\pi r_2) & j \text{ 为奇数} \end{cases} \quad (8)$$

式中: x_{ij}^{t+1} 为下一次迭代时,第 i 个个体在 j 维上的位置; $x_{i,p}^t$ 为在本次迭代时第 i 个个体在随机维度 p 维上的位置; $x_{r,p}^t$ 为在本次迭代时随机个体 r 在随机维度 p 维上的位置。

(2) 开发阶段

开发阶段是白鲸的捕食行为的体现。在开发阶段引入 Levy 飞行策略增强算法的收敛性,其数学模型表示为

$$x_i^{t+1} = r_3 x_{\text{best}}^t - r_4 x_i^t + C_1 L_F(x_i^t - x_i^t) \quad (9)$$

$$C_1 = 2 \times r_4 \left(1 - \frac{t}{T}\right) \quad (10)$$

式中: C_1 为随机跳跃度,用来衡量 Levy 飞行的强度; r_3 、 r_4 均为 $(0,1)$ 之间的随机数; L_F 为一个符合 Levy 分布的随机数,计算方式为

$$L_F = 0.05 \times \frac{\mu\sigma}{|v|^{\frac{1}{\beta}}} \quad (11)$$

$$\sigma = \left(\frac{\Gamma(1+\beta) \times \sin(\pi \cdot \frac{\beta}{2})}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\frac{\beta-1}{2}}} \right)^{\frac{1}{\beta}} \quad (12)$$

$$\Gamma(x) = (x-1)! \quad (13)$$

式中: μ , v 均服从正态分布,即 $\mu, v \sim N(0,1)$, β 是一个常数,取 1.5。

(3) 鲸落阶段

鲸落阶段是白鲸死亡坠落的体现。用白鲸当前的位置和鲸落下坠的步长来建立位置公式

$$x_i^{t+1} = r_5 \cdot x_i^t - r_6 \cdot x_r^t + r_7 \cdot x_{\text{step}}^t \quad (14)$$

$$x_{\text{step}}^t = e^{-\frac{C_2 \cdot t}{T}} (b^U - b^L) \quad (15)$$

式中: r_5 , r_6 , r_7 均为 $(0,1)$ 之间的随机数; b^U 和 b^L 分别为优化问题的上界和下界; x_r^t 为随机个体 r 的位置; x_{step}^t 为鲸落下坠的步长; C_2 为阶跃因子,阶跃因子与鲸落的概率和种群规模有关,计算公式为

$$C_2 = 2W_t N \quad (16)$$

$$W_t = 0.1 - 0.05 \times \frac{t}{T} \quad (17)$$

鲸落的概率由初始的 0.1 减小到最后的 0.05,说明迭代过程中,白鲸离食物越近,受到的危险越小。

(4) 计算流程

BWO 具体的计算流程如图 2 所示。




图2 BWO 计算流程

Fig. 2 BWO calculation process

1.3 组合模型

LSTM 的超参数(隐藏层神经元维度、隐藏层层数、dropout、学习率)和参数(权重、偏差)对 LSTM 预测的精度影响很大,而随机选取的参数值使模型的预测结果相差甚远。因此,通过将 BWO 的适应度函数定义为 LSTM 在训练集上的预测误差对这 4 个关键参数进行寻优,找到最优适应度值对应的最优 LSTM 模型,以此来解决 LSTM 参数设置困难的问题,从而提高电力负荷预测的精度。BWO-LSTM 模型算法流程如图 3 所示。




图3 BWO-LSTM组合模型算法流程

Fig. 3 BWO-LSTM combined model algorithm flow

2 算例分析

2.1 算例介绍

随机选取了华北、华中和华南3个地区的3个城市全社会用电为研究对象,分别采集了不同月份的电力负荷数据。负荷采集频率为15 min/次,即96个/d采集数据,总共2 976个负荷数据。同时,收集当地天气最高温度;最低温度以及日类型等数据,选取其中前75%(23 d)的数据作为训练集,后25%(8 d)的数据作为测试集。

图4为某市某一周的电力负荷曲线图,起始点为周日的00:00。从图4可以看出,电力负荷曲线形状近似,1 d有两个峰值、两个谷值,且极值点时间相近,具有较强的周期性。




图4 某一周的电力负荷曲线

Fig. 4 Power load curve of a certain week

2.2 数据预处理及评价指标

标准化处理就是将数据按照某一特定的比例进行缩放,使数据落入特定的区域以便于进行综合分析。

最大最小归一化是数据标准化的一种,计算公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (18)$$

式中: x' 为单个数据的取值; $x_{\min}$ 为数据所在列的最小值; $x_{\max}$ 为数据所在列的最大值。

为了更好地评估模型的性能,使用平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)两种性能评价指标对预测结果进行分析。

M_{APE} 和 R_{MSE} 的计算公式分别为

$$M_{APE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (19)$$

$$R_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (20)$$

式中: n 为电力负荷的数量; $\hat{y}_i$ 为第 i 个电力负荷的实际值; y_i 为第 i 个电力负荷的预测值。一般情况下, M_{APE} 和 R_{MSE} 的值越小表示预测精度越高。

2.3 仿真分析

为了验证模型的有效性,设置CNN、Transformer、Informer、Autoformer作为对比模型,同时选用WOA、PSO、GWO优化方法对LSTM进行优化预测。其中,各优化方法设置种群规模为20、最大迭代次数为150次、变量维度为4, LSTM设置优化器为Adam、迭代次数为100次。为保证预测结果的可靠性,所有的结果经过模型20次训练并预测得到的平均值。模型均在Python3.8开发环境下搭建,运行设备为Windows10 64位操作系统,处理器为Intel(R) Core(TM) i5-4210H CPU @ 2.90 GHz,运行内存RAM为8 G。

为验证日类型与天气因素对短期电力负荷预测的影响效果,增设考虑日类型、考虑天气因素、考虑日类型及天气因素3个场景对负荷数据预测研究。

各个场景的模型预测结果如图5所示,预测误差如表1所示。从结果可以看出,日类型与天气因素对电力负荷预测的影响程度存在显著差异。在仅考虑日类型的情况下,模型的预测的 M_{APE} 为19.36%,表明单独考虑日类型时,预测结果受到的约束较为有限,无法充分捕捉到电力负荷变化的复杂性。相比之下,当考虑到天气因素时,模型预测的 M_{APE} 减小至11.99%,这表明天气因素在电力负荷预测中发挥了更为重要的作用。因此,天气因素相较于日类型,对电力负荷的预测精度和可靠性具有更大的贡献。




图5 各个场景预测结果与实际值对比

Fig. 5 Prediction results of each scene are compared with the actual values

表1 各个场景预测误差			
Table 1 Prediction error of each scene			
场景	$M_{APE} / \%$	R_{MSE} / MW	
考虑日类型	19.36	536.31	
考虑天气因素	11.99	297.48	
考虑日类型及天气因素	2.70	62.46	

各个模型的预测结果以及经不同优化方法优化后预测结果分别如图6和图7所示,预测误差及预测消耗时间结果如表2和表3所示。通过短期负荷预测结果和预测误差评价指标可以看出,在未经优化的预测模型中,LSTM和Transformer模型的预测值与真实负荷值的差异较小,且两者的预测曲线与实际值的走势非常相似,表现出较好的拟合效果。然而,进一步分析预测误差指标后可以发现,LSTM模型在各项评价指标上表现更为优异,相比于Transformer模型,LSTM的 M_{APE} 平均降低了0.22%, R_{MSE} 平均减少了19.32 MW,且预测时长远明显减少,表明LSTM模型的预测精度与预测效率相

对较高,误差也较小。这一差异表明,LSTM模型对于电力负荷的短期变化趋势能够更好地进行捕捉,且在对误差的控制上表现更佳。与之相比的是CNN模型的预测误差明显偏大,其预测结果与真实值之间存在较为明显的差距,且预测误差指标较为不理想。

经过优化后,LSTM模型的预测效果得到了显著提升,优化后的模型在预测精度和预测时间方面表现出明显的改善。尤其是BWO-LSTM模型,相较于未优化的LSTM模型,其在多个性能指标上均展示了优异的表现。具体来说,BWO-LSTM模型的 M_{APE} 平均降低了9.06%,而 R_{MSE} 平均减少了952.90 MW,这表明BWO-LSTM模型在提高预测精度的同时,显著降低了误差。此外,BWO-LSTM模型的预测时间平均减少了90.29 s,表明其在效率方面也得到了极大的提升,显著缩短了模型的计算时间,提升了预测过程的整体效率。




图6 各个模型预测结果与实际值对比

Fig. 6 Prediction results of each model are compared with the actual values

表2 各个模型预测误差												
Table 2 Prediction error and time of each model												
数据集	BWO-LSTM			CNN			Transformer			Informer		
	$M_{APE} / \%$	R_{MSE} / MW	时间/ s	$M_{APE} / \%$	R_{MSE} / MW	时间/ s	$M_{APE} / \%$	R_{MSE} / MW	时间/ s	$M_{APE} / \%$	R_{MSE} / MW	时间/ s
地区1	6.70	212.46	77.99	22.57	1 232.83	324.86	19.62	967.35	794.85	9.35	378.93	537.19
地区2	12.88	2 359.73	93.17	25.16	5 867.39	345.82	20.81	4 231.89	764.88	15.68	3 841.57	569.23
地区3	2.35	132.21	69.42	17.45	781.49	314.52	9.35	421.83	724.09	4.17	221.06	517.24

表3 各个优化模型预测误差
Table 3 Prediction error and time of each optimization model

数据集	LSTM			BWO-LSTM			WOA-LSTM			PSO-LSTM			GWO-LSTM		
	M_{APE} / %	R_{MSE} / MW	时间/ s	M_{APE} / %	R_{MSE} / MW	时间/ s	M_{APE} / %	R_{MSE} / MW	时间/ s	M_{APE} / %	R_{MSE} / MW	时间/ s	M_{APE} / %	R_{MSE} / MW	时间/ s
地区1	18.28	945.62	204.68	6.70	212.46	77.99	10.27	546.76	67.52	12.31	613.51	66.89	9.93	375.31	93.47
地区2	20.56	5 173.69	143.35	12.88	2 359.73	93.17	15.09	3 274.24	106.31	13.05	2 816.02	112.22	16.35	4 013.61	91.25
地区3	10.28	433.79	163.42	2.35	132.21	69.42	5.62	284.29	78.23	7.34	382.09	83.14	4.28	217.75	75.32




图7 经优化后预测结果与实际值对比

Fig. 7 Optimized prediction results are compared with the actual values

此外,相较于WOA、PSO、GWO优化之后的LSTM模型,BWO-LSTM模型展现出了更为优越的预测性能。具体表现为:与WOA优化的LSTM相比,BWO-LSTM的 M_{APE} 降低了3.02%, R_{MSE} 降低了466.96 MW,预测时间减少了3.83 s;与PSO优化的LSTM相比,BWO-LSTM的 M_{APE} 降低了3.59%, R_{MSE} 降低了369.07 MW,预测时间减少了7.22 s;与GWO优化的LSTM相比,BWO-LSTM的 M_{APE} 降低了2.88%, R_{MSE} 降低了633.95 MW,预测时间减少了6.49 s。这些结果进一步验证了BWO优化方法在提高LSTM预测模型精度与效率方面的显著优势。

然而,尽管BWO-LSTM模型的预测误差在与Informer和Autoformer方法进行对比时并未呈现出显著的下降,但其在预测算法运行时间上的显著缩短,提升了模型的应用效率,使得BWO-LSTM在实际应用中更加高效,显示了其在实际应用中的巨大潜力和应用价值。

从这些数据可以看出,BWO-LSTM模型不仅在预测精度上更优,而且其预测结果更加稳定,能够

更好地应对电力负荷波动带来的不确定性。表明模型在短期电力负荷预测领域具有更强的适应性和可靠性,能够为电力系统的调度和管理提供更为精准的预测支持,提升电力需求侧管理的效率。因此,BWO-LSTM模型在短期电力负荷预测任务中的优势不容忽视,尤其适用于对预测精度和稳定性有较高要求的实际应用场景。

3 结束语

为了提高短期电力负荷预测的精度以及预测结果的稳定性,同时考虑到外部天气等因素的影响,本文提出了一种基于白鲸优化算法与长短期记忆网络模型相结合的预测方法,并验证所提方法,结论如下:

(1) 将日类型及天气因素等外部因素引入电力负荷预测模型,有效地扩展了模型的学习空间,增强了其对复杂环境因素的适应能力。电力负荷不仅受到时间因素的影响,还受天气、节假日等外部条件的影响。通过将日类型和天气因素作为输入特征,LSTM模型能够学习到这些外部因素与负荷之间的复杂关系,从而提升预测的准确性。

(2) 利用BWO算法对LSTM模型的参数和超参数进行优化,显著提升了模型的鲁棒性与优越性。BWO算法能够在多次迭代中精确地调整LSTM的参数,并确保这些参数快速收敛到最优解。与传统的优化方法不同,BWO能够有效避免陷入局部最优解的困境,确保找到全局最优解,从而提升了LSTM模型的预测性能和稳定性。

(3) BWO-LSTM模型不仅能够识别电力负荷数据中的特征和趋势,还能揭示电力负荷历史数据与影响因素之间的潜在相关性和映射关系。通过引入BWO优化LSTM参数的策略,模型能够深度学习

并捕捉数据中的非线性模式,从而更准确地预测未来的电力负荷。通过这种方法,未来可以进一步优化电力负荷预测,提供更精准的数据支持,进而促进电力系统的智能化与高效化管理。D

参考文献:

- [1] PINHEIRO M G, MADEIRA S C. Short-term electricity load forecasting—a systematic approach from system level to secondary substations [J]. *Applied Energy*, 2023, 332.
- [2] 李刚, 邹波. 改进随机森林的电力负荷预测方法[J]. *机械设计与制造*, 2019(10): 103–105, 109.
LI Gang, ZOU Bo. Improving the power load forecasting method of random forest [J]. *Mechanical design and manufacturing*, 2019(10): 103–105, 109.
- [3] 陈家乾, 肖艳炜, 李英, 等. 多变量相空间重构的多核最小二乘支持向量机电力负荷预测优化策略[J]. *科学技术与工程*, 2020, 20(29): 11 956–11 962.
CHEN Jiaqian, XIAO Yanwei, LI Ying, et al. Optimization strategy of multi-kernel least squares support vector machine power load forecasting based on multi-variable phase space reconstruction [J]. *Science and Technology and Engineering*, 2020, 20(29): 11 956–11 962.
- [4] 白登辉. 计及偏差电量考核机制的人工神经网络售电量预测模型[J]. *电工电能新技术*, 2020, 39(6): 58–66. DOI: 10.12067/ATEEE1904043.
BAI Denghui. Artificial neural network electricity sales forecasting model considering deviation electricity assessment mechanism [J]. *New technology of electrical energy*, 2020, 39(6): 58–66. DOI: 10.12067/ATEEE1904043.
- [5] 王晓辉, 邓威威, 齐旺. 基于超参数优化的短期电力负荷预测模型[J]. *国外电子测量技术*, 2022, 41(6): 152–158.
WANG Xiaohui, DENG Weiwei, QI Wang. Short-term power load forecasting model based on hyper-parameter optimization [J]. *Foreign electronic measurement technology*, 2022, 41(6): 152–158.
- [6] 刘倩倩, 刘钰山, 温烨婷, 等. 基于PCC-LSTM模型的短期负荷预测方法[J]. *北京航空航天大学学报*, 2022, 48(12): 2 529–2 536.
LIU Qianqian, LIU Yushan, WEN Yehua, et al. Short-term load forecasting method based on PCC-LSTM model [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(12): 2 529–2 536.
- [7] 王繁. LSTM与CNN对配电台区短期负荷预测的适用性研究[D]. 兰州: 兰州交通大学, 2021.
WANG Fan. Research on the applicability of LSTM and CNN to short-term load forecasting in distribution stations [D]. Lanzhou: Lanzhou Jiaotong University, 2021.
- [8] GAO X, LIU J, YUAN Y, et al. Global horizontal irradiance prediction model considering the effect of aerosol optical depth based on the Informer model [J]. *Renewable Energy*, 2024, 220.
- [9] ZHOU S, ZHANG X, LIU J, et al. Long-Term Prediction of Particulate Matter 2.5 Concentration with Modal Autoformer Based on Fusion Modal Decomposition Algorithm [J]. *Atmosphere*, 2023, 15(1):
- [10] 宋思远, 朱武, 王光东, 等. 基于IPSO-LSTM神经网络的短期负荷预测[J]. *计算机仿真*, 2021, 38(8): 92–96.
SONG Siyuan, ZHU Wu, WANG Guangdong, et al. Short-term load forecasting based on IPSO-LSTM neural network [J]. *Computer simulation*, 2021, 38(8): 92–96.
- [11] 王金玉, 金宏哲, 王海生, 等. ISSA优化Attention双向LSTM的短期电力负荷预测[J]. *电力系统及其自动化学报*, 2022, 34(5): 111–117.
WANG Jinyu, JIN Hongze, WANG Haisheng, et al. ISSA optimizes the short-term power load forecasting of Attention bidirectional LSTM [J]. *Journal of Power System and Automation*, 2022, 34(5): 111–117.
- [12] 简定辉, 李萍, 黄宇航. 基于GA-VMD-ResNet-LSTM网络的短期电力负荷预测[J]. *国外电子测量技术*, 2022, 41(10): 15–22.
JIAN Dinghui, LI Ping, HUANG Yuhang. Short-term power load forecasting based on GA-VMD-ResNet-LSTM network [J]. *Foreign electronic measurement technology*, 2022, 41(10): 15–22.
- [13] 高超, 孙谊嫔, 赵洪峰, 等. 改进的黑猩猩算法优化LSTM的短期电力负荷预测[J]. *现代电子技术*, 2022, 45(21): 122–126.
GAO Chao, SUN Yiqian, ZHAO Hongfeng, et al. Short-term power load forecasting of LSTM optimized by improved chimpanzee algorithm [J]. *Modern Electronic Technology*, 2022, 45(21): 122–126.
- [14] 谢国民, 王润良. 基于改进金豺算法的短期负荷预测[J/OL]. *电力系统及其自动化学报*: 1–9 [2024-02-27].
XIE Guomin, WANG Runliang. Short-term load forecasting based on improved golden jack algorithm [J/OL]. *Journal of Power System and Its Automation*: 1–9 [2024-02-27].
- [15] ZHENG Y, LEI Q, MINGKUN S, et al. Ionospheric foF2 nowcast based on a machine learning GWO-ALSTM model [J]. *Advances in Space Research*, 2023, 72(11): 4 896–4 910.
- [16] RAN Y, XU X, LUO M, et al. Scene classification method based on multi-scale convolutional neural network with long short-term memory and whale optimization algorithm [J]. *Remote Sensing*, 2023, 16(1).
- [17] CHANGTING Z, GANG L, ZENG M. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm [J]. *Knowledge-Based Systems*, 2022, 251.

作者简介:

王云佳(1993), 女, 河北石家庄人, 硕士, 研究方向为电力负荷预测、电力市场;

马国真(1985), 男, 河北保定人, 高级经济师, 研究方向为电力经济、电力大数据应用。

(责任编辑 水 鹤 崔素媛)