

# 基于相似日和IWOA优化BiLSTM的短期电力负荷预测

朱莉<sup>a</sup>, 李豪<sup>b\*</sup>, 汪小豪<sup>b</sup>, 姜成龙<sup>b</sup>, 曹明海<sup>b</sup>

(湖北工业大学 a. 太阳能高效利用及储能运行控制湖北省重点实验室; b. 电气与电子工程学院, 武汉 430068)

**摘要** 为了有效提升短期负荷预测的精度,提出了一种基于相似日和IWOA优化BiLSTM的短期电力负荷预测模型.该模型首先利用Pearson相关性分析选取负荷的主要影响因素,并利用综合匹配相似度选取相似日,为模型提供更有利的输入;然后研究了一种基于非线性控制参数策略和种群变异策略的IWOA算法,对BiLSTM网络的参数进行寻优,构建IWOA-BiLSTM预测模型;最后以澳大利亚真实负荷数据集作为实际算例进行验证,结果表明:该预测模型相较于其他模型获得了更高的预测精度,证明了该方法的有效性.

**关键词** 短期负荷预测;改进鲸鱼优化算法;相似日;双向长短期记忆网络;超参数寻优

**中图分类号** TP181;TM411 **文献标志码** A **文章编号** 1672-4321(2025)04-0507-08

**doi**:10.20056/j.cnki.ZNMDZK.20240752

## Short-term power load forecasting based on similar days and IWOA optimized BiLSTM

ZHU Li<sup>a</sup>, LI Hao<sup>b\*</sup>, WANG Xiaohao<sup>b</sup>, JIANG Chenglong<sup>b</sup>, CAO Minghai<sup>b</sup>

(Hubei University of Technology, a. Hubei Key Laboratory for High-efficiency Utilization of Solar Energy and Operation Control of Energy Storage System; b. School of Electrical and Electronic Engineering, Wuhan 430068, China)

**Abstract** In order to effectively improve the accuracy of short-term load forecasting, a short-term power load forecasting model based on similar days and IWOA optimized BiLSTM was proposed. The model first uses Pearson correlation analysis to select the main influencing factors of the load, and uses the comprehensive matching similarity to select the similar day to provide more effective input for the model; then an IWOA algorithm based on a nonlinear control parameter strategy and a population variation strategy is designed to optimize the parameters of the BiLSTM network and build the IWOA-BiLSTM prediction model; finally, taking the Australian real load data set as an example, the experimental results show that the prediction model proposed has higher prediction accuracy than other models, which proves the effectiveness of this method.

**Keywords** short-term load forecasting; improved whale optimization algorithm; similar day; bidirectional long short-term memory network; hyperparameter optimization

短期负荷预测(short-term load forecasting, STLFL)主要是通过分析历史负荷数据来预测未来几小时或几天的负荷,STLFL对电力系统的安全稳定运行至关重要,能够为电力系统的生产计划和电力调度提供科学的依据,负荷预测的准确性直接影响电力系统的安全性和经济性<sup>[1-2]</sup>.

随着人工智能技术的发展,深度学习网络在短期电力负荷预测领域中得到了广泛的应用<sup>[2]</sup>.长短期记忆网络(long short-term memory, LSTM)是循环神经网络(recurrent neural network, RNN)的一种特殊变体,通过在RNN的基础上添加门结构,解决了RNN存在的梯度消失和梯度爆炸问题,能够学习时

**收稿日期** 2023-03-08 \* **通信作者** 李豪,研究方向:人工智能在电力系统中的应用,E-mail:906814569@qq.com

**作者简介** 朱莉(1982-),女,副教授,博士,研究方向:人工智能与大数据,E-mail:810745390@qq.com

**基金项目** 新能源及电网装备安全监测湖北省工程研究中心开放研究基金资助项目(HBSKF202124)

间序列数据中的长距离依赖关系<sup>[4-7]</sup>.但是 LSTM 网络只能按照时间序列顺序处理数据,只考虑到了正序信息<sup>[8]</sup>.而 BiLSTM<sup>[9-11]</sup>是正向 LSTM 和反向 LSTM 的组合,它可以从正向和反向拟合数据,达到更高的预测精度.文献[12]采用 BiLSTM 构建预测模型,结果表明,BiLSTM 相比传统的 LSTM 具有更好的预测效果.

近年来,针对深度学习算法存在超参数难以确定,容易出现欠拟合或过拟合的问题,有学者提出了超参数寻优方法<sup>[13-15]</sup>.文献[16]采用粒子群优化算法(particle swarm optimization, PSO)对 LSTM 进行优化,有效提高了模型的预测能力,但是 PSO 在优化过程中存在容易陷入局部最优的问题.文献[17]提出了一种多算法融合预测模型,并利用全局寻优能力强的鲸鱼优化算法(whale optimization algorithm, WOA)对模型权重进行优化,有效提升了短期电力负荷预测精度.文献[18]利用改进鲸鱼优化算法(improved whale optimization algorithm, IWOA)对 LSTM 进行优化,在 WOA 中引入随机种群变异,避免其早熟收敛,该模型相较于传统的 LSTM 获得了更高的预测精度.根据以上研究,为了进一步提升 BiLSTM 的预测精度,研究了一种 IWOA 算法,首先在 WOA 中加入非线性控制参数策略平衡其局部寻优和全局搜索的能力,然后加入基于卡方分布的概率变异策略,提高其跳出局部最优的能力.

考虑到负荷影响因素复杂,短期负荷呈现较强的波动性,首先对原始数据进行处理,利用 Pearson 相关性分析选取负荷主要影响因素,并提出一种基于综合匹配相似度的相似日提取方法;然后构建了一种基于改进 WOA 算法优化 BiLSTM 的短期负荷预测模型;最后在真实负荷数据集上验证该方法的有效性.

## 1 电力负荷数据处理

### 1.1 电力负荷影响因素分析

在负荷预测中,负荷值和影响因素之间存在一定的关联性,但不同影响因素相关性的大小不同,而且影响负荷变化的程度也不同.因此,首先对输入的特征进行处理,选取主要影响因素.本文采用 Pearson 相关性分析计算得出不同因素对负荷的影响程度,相关性系数越大说明相关因素对负荷的影响程度越大,相关系数的计算公式如下:

$$P_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (1)$$

式中, $x_i$ 表示负荷的影响因素, $y_i$ 表示负荷, $\bar{x}$ 和 $\bar{y}$ 表示均值.

### 1.2 相似日选取

相似日是指与待预测日的影响因素相似的历史日样本,选取出历史数据中的相似日作为模型输入,能够更有效地对未来负荷进行预测.本文提出了一种综合匹配相似度的相似日提取方法,分别计算气象、星期类型和时间的相似度,然后加权求和得到综合匹配相似度,选取综合匹配相似度较大的历史日作为相似日.综合匹配相似度计算步骤如下:

#### 1.2.1 气象相似度

首先通过 Pearson 相关性分析选取相关程度最大的气象因素,然后利用灰色关联分析计算历史样本日和待预测日的气象相似度.计算公式如下:

$$\sigma_i = \frac{1}{n} \sum_{k=1}^n \frac{\min_k |Y(k) - X_i(k)| + \rho \max_k |Y(k) - X_i(k)|}{|Y(k) - X_i(k)| + \rho \max_k |Y(k) - X_i(k)|}, \quad (2)$$

式中, $Y(k)$ 为参考序列, $X_i(k)$ 为比较序列, $\rho$ 为分辨系数,其越小,分辨能力越大,本文中取值为 0.5, $\min_k |Y(k) - X_i(k)|$ 为取最小值, $\max_k |Y(k) - X_i(k)|$ 为取最大值.

#### 1.2.2 星期类型相似度

星期类型相似度是待预测日与历史日在日期类型上的相似程度,计算公式如下:

$$\gamma_i = 1 - |f(X_i) - f(X_0)|, \quad (3)$$

式中, $X_i$ 和 $X_0$ 分别为历史日和预测日的星期类型, $f(X_i)$ 和 $f(X_0)$ 表示星期类型映射后的值,其中周一的映射值为 0.1,周二至周四的映射值为 0.2,周五的映射值为 0.3,周六的映射值为 0.7,周天的映射值为 1.

#### 1.2.3 时间相似度

时间相似度是待预测日与历史日在时间上的相似程度,在计算上采用近大远小的原则,同时考虑负荷的周期性变化规律,计算公式如下:

$$\delta_i = \beta_1^{\text{mod}(t, N_1)} \beta_2^{\text{int}(t/N_1)}, \quad (4)$$

式中, $t$ 表示历史日距离预测日的天数, $\beta_1$ 和 $\beta_2$ 为衰减系数,取值范围为[0.9, 0.98],分别表示时间距离每增加一天和一周的缩减比例,mod 为取余操作,int

为取整操作,  $N_1$ 和 $N_2$ 为常数,取值为7.

### 1.2.4 综合匹配相似度

综合匹配相似度是由气象相似度、星期匹配相似度和时间相似度加权求和得到,公式如下:

$$\begin{cases} r_i = S_1\sigma_i + S_2\gamma_i + S_3\delta_i \\ S_i = \frac{P_i}{P_1 + P_2 + P_3} \end{cases}, \quad (5)$$

式中 $S_1$ 、 $S_2$ 和 $S_3$ 分别是气象匹配相似度、星期类型匹配相似度和时间匹配相似度的权值, $P_i$ 为不同影响因素的Pearson相关性系数.

## 2 基于IWOA-BiLSTM的短期电力负荷预测模型

### 2.1 改进鲸鱼优化算法

鲸鱼优化算法是根据鲸鱼捕食行为获得启发的一种智能优化算法,是由MIRJALILI等于2016提出<sup>[19-20]</sup>.该算法包括围捕猎物、气泡网捕食和搜寻猎物三个重要阶段,阶段的选择主要由随机概率因子 $p$ 和系数 $|A|$ 决定.但WOA算法面对复杂的寻优问题时,也存在着不能有效地转换全局搜索和局部寻优,以及容易陷入局部最优的问题.为了进一步提升WOA算法的优化性能,本文研究了一种改进鲸鱼优化算法,具体改进策略如下.

#### 2.1.1 非线性控制参数策略

鲸鱼优化算法通过系数 $|A|$ 来平衡其全局搜索和局部寻优的能力,以获得较好的寻优效果.当 $|A| < 1$ 时,算法通过收缩包围机制和螺旋更新位置,来实现局部寻优的目的;当 $|A| > 1$ 时,算法进行随机搜寻猎物实现全局寻优.系数 $A$ 主要随着参数 $a$ 的变化而改变,即WOA寻优过程中全局搜索和局部寻优的转换是由参数 $a$ 控制.然而,参数 $a$ 的值是从2线性递减到0,这种线性递减策略不能适应一些复杂的寻优过程,会导致陷入局部最优和收敛精度低的问题.针对以上问题,本文采用正弦函数构建参数 $a$ 的非线性动态变化策略.

$$a(t) = (a_{\text{initial}} - a_{\text{final}}) \times \sin\left(\mu \frac{t}{T_{\text{max}}}\pi\right), \quad (6)$$

式中 $a_{\text{initial}}$ 为参数初始值, $a_{\text{final}}$ 为参数终止值, $\mu$ 为非线性控制系数.

#### 2.1.2 种群变异策略

在WOA算法中,其他鲸鱼个体更新位置方式都是在当前个体和当前最优个体 $X^*$ 附近随机产生

新的个体,假设该最优个体 $X^*$ 为局部最优解,随着迭代次数的增加,则鲸鱼群体中其他个体会由 $X^*$ 引导聚集至局部最优解附近,导致群体失去多样性,使得算法早熟收敛,收敛精度低.针对上述问题,在WOA中引入种群变异思想,个体位置在更新时可能出现变异,产生新的变异个体,以增强算法迭代过程中跳出局部最优的能力.

引入卡方分布来表示发生变异的概率,卡方分布的概率密度函数由以下公式表示:

$$P = \left(\frac{t}{10}\right)^{\frac{v}{2}-1} e^{-\frac{t}{20}} \frac{4}{2^{v/2}(v/2)!}, \quad (7)$$

其中, $v$ 为自由度系数,取值为4,概率密度函数分布如图1所示.




图1 概率密度函数分布

Fig. 1 Probability density function distribution

为了保证种群的多样性,变异程度由当前鲸鱼个体、当前最优个体和群体中随机选择的鲸鱼个体决定,变异发生的约束公式如下:

$$\begin{aligned} X(t+1) &= r_1 \times (X_p - X(t)) + r_2 (X'(t) - X(t)), \\ P &> P_z, \end{aligned} \quad (8)$$

式中, $r_1$ 和 $r_2$ 为 $[0, 1]$ 之间的随机数, $X_p$ 为当前最优个体位置, $X'(t)$ 为种群中随机选择的个体, $P_z$ 为突变概率阈值.根据概率分布图和变异发生的约束公式可知,在搜索初期,鲸鱼个体变异概率慢慢增大,可以增加鲸鱼种群的丰富度,有效避免陷入局部最优,而在搜索后期,个体变异概率慢慢降低,便于算法进行局部寻优,提高算法搜索速度.

### 2.2 IWOA算法寻优能力测试

选择Shubert非线性函数作为优化算法的测试函数,该函数有很多局部最小值,寻优难度较高,可以有效验证优化算法的寻优能力,Shubert函数的数学公式如下所示.

$$f(x_1, x_2) = \sum_{i=1}^5 (i \cos((i+1)x_1 + i)) \times \sum_{i=1}^5 (i \cos(((i+1)x_2 + i))),$$

$$-10 \leq x_1, x_2 \leq 10. \quad (9)$$

选取 WOA 算法和 PSO 算法与 IWOA 作对比分析, 算法的迭代次数设置为 200, 随着迭代次数增加, 最优适应度变化情况如图 2 所示.

由图 2 可知, PSO 算法在第 98 次迭代时收敛, 收敛速度较慢, 收敛误差为  $6.97 \times 10^{-3}$ , WOA 算法收敛速度较快, 在第 77 次迭代找到全局最优解, 而 IWOA 在迭代第 36 次就找到了全局最优解, 收敛速度最快.

### 2.3 IWOA-BiLSTM 预测模型

为了提高 BiLSTM 的预测精度, 采用改进鲸鱼优化算法来优化 BiLSTM 的隐藏层神经元个数  $h$  和




图 2 不同优化算法性能对比图

Fig. 2 Performance comparison diagram of different optimization algorithms

学习率  $r$  两个主要参数, 优化的隐藏层神经元个数  $h$  和学习率  $r$  的搜索范围分别为  $[1, 300]$  和  $[0.001, 0.1]$ . IWOA 优化 BiLSTM 的流程图如图 3 所示.

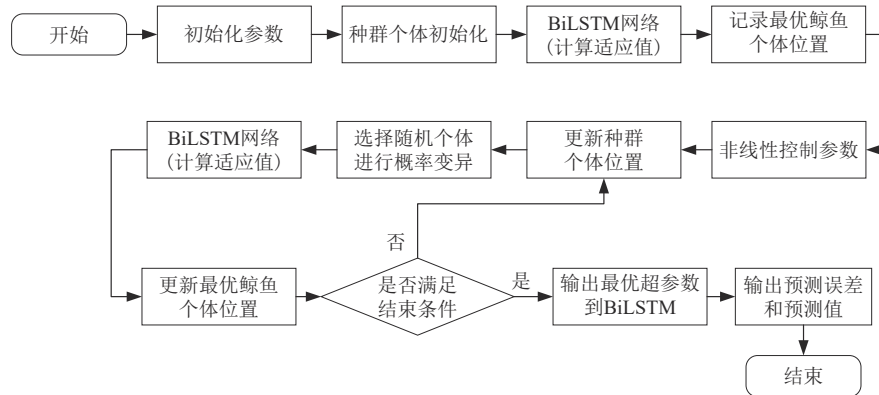


图 3 IWOA-BiLSTM 预测模型流程图

Fig. 3 Flowchart of IWOA-BiLSTM prediction model

(1) 初始化模型参数. 确定 BiLSTM 的输入层和输出层节点数, IWOA 算法的种群数量、最大迭代次数.

(2) 利用得到的种群个体参数构建 BiLSTM 模型, 输出模型预测值, 然后以预测值的均方根误差作为适应度函数, 计算种群个体适应度值, 并记录适应度最低的个体位置.

(3) 根据非线性控制参数策略, 来选择围捕猎物、气泡网捕食和随机搜寻猎物方式更新种群个体.

(4) 为了提升种群丰富度, 根据种群变异策略进行随机变异扰动, 产生随机变异个体, 避免算法过早收敛, 陷入局部最优.

(5) 若达到最大迭代次数, 则输出最优的参数  $h$  和  $r$ , 若未达到, 返回步骤 2, 进行下一次迭代.

(6) 在最优超参数下构建 BiLSTM 预测模型, 输出最终的预测值和预测误差.

## 3 实验与结果分析

实验数据来自澳大利亚能源市场运营商, 选取 NSW 地区的电力负荷数据作为实验数据集. 实验使用了 2020 年 10 月的负荷数据, 负荷采集时间间隔为半小时, 每天采集 48 条数据, 数据集中包含电力负荷和气象数据. 本文将数据集的前 30 d 作为训练集, 对模型参数进行训练, 剩余的数据作为测试集.

### 3.1 模型预测流程

本文针对负荷影响因素复杂和 BiLSTM 网络参数难以确定的问题, 提出了一种基于相似日和 IWOA-BiLSTM 的短期电力负荷预测模型. 该负荷预测模型流程图如图 4 所示.

(1) 数据的收集和预处理. 收集和整理电力负荷数据集, 然后利用均值对比方法对负荷数据集中的异常值进行检测和修正.

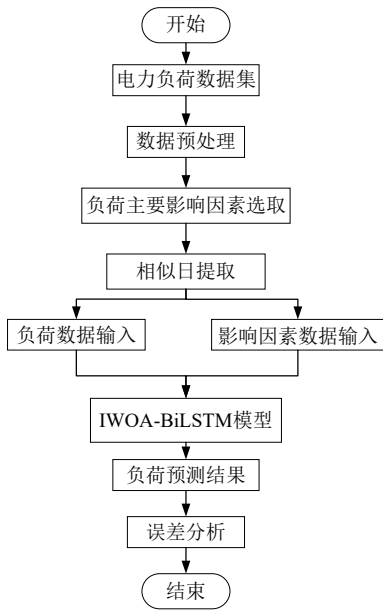


图4 基于相似日和IWOA-BiLSTM模型预测流程图

Fig. 4 Flow chart of prediction based on similar days and IWOA-BiLSTM model

(2)选取负荷的主要影响因素.利用 Pearson 相关性分析选取主要影响因素作为模型的输入,降低不相关或相关性较弱的特征因素对负荷预测的影响.

(3)相似日提取.计算历史负荷数据的气象相似度、星期相似度和时间相似度,并加权求和得到历史负荷数据的综合匹配相似度,然后根据综合匹配相似度大小选取合适的相似日,为模型提供更有效的输入.

(4)构建 IWOA-BiLSTM 模型.首先在 WOA 算法中加入线性控制参数改进策略和种群变异策略,提高 WOA 算法的寻优能力,然后在此基础上利用 IWOA 算法对 BiLSTM 的神经元数量和学习率参数进行寻优,得到最优预测模型,输出负荷预测值.

### 3.2 相似日的选取

考虑到负荷影响因素复杂,针对影响电力负荷数据的因素进行相关性分析,计算各个影响因素的 Pearson 相关性系数,各因素的相关性系数如表 1 所示.

表1 不同影响因素的相关性系数

Tab. 1 Correlation coefficient of different influencing factors

影响因素	湿度	干球温度	湿球温度	露点温度	时间	星期类型
相关系数	0.273	0.364	0.196	0.067	0.282	0.313

由表 1 可知,干球温度的相关系数为 0.364,相较于其他影响因素表现出更强的相关性,因此选择干球温度作为主要影响因素.然后根据公式(6)可

以计算出气象、星期类型和时间的匹配相似度权重 S1、S2、S3 分别为 0.38、0.32、0.3. 以 2020 年 10 月 31 日为待预测日,其他的数据作为历史数据,计算历史日的综合匹配相似度,选择相似度较大的历史样本日作为相似日,计算得到的综合匹配相似度前十的排序如图 5 所示.




图5 相似度排序

Fig. 5 Similarity ranking

由图 5 可知,选取相似度大于 0.6 的 10 月 17 日、10 月 9 日、10 月 18 日、10 月 30 日、10 月 14 日、10 月 21 日、10 月 12 日和 10 月 19 日共 8 d 作为相似日.

### 3.3 预测结果分析

本文通过三个指标来衡量短期电力负荷预测方法的性能,分别为均方根误差(Root Mean Square Error, RMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)和决定系数  $R^2$ ,计算公式如下.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2}, \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - p_i}{y_i} \right| \times 100\%, \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (12)$$

式中,  $y_i$  表示真实负荷值,  $p_i$  表示预测值,  $\bar{y}$  表示负荷平均值.

将选取的相似日负荷数据和特征数据构建新的数据序列,作为 IWOA-BiLSTM 预测模型的训练数据.为了验证是否相似日对模型预测精度的提升效果是否有差异,分别在相似日下和普通日下进行对比实验,预测结果如表 2 所示.

由表 2 可知,考虑相似日下的 IWOA-BiLSTM 模

表2 考虑和不考虑相似日的模型预测结果对比

Tab. 2 Comparison of forecast results with and without similar days

预测模型	RMSE/MW	MAPE/%	$R^2$
考虑相似日	127.649	1.186	0.944
不考虑相似日	147.193	1.414	0.926

型的预测精度更高,较不考虑相似日的RMSE和MAPE误差指标分别降低了19.544 MW和16.1%,决定系数提升了1.9%。由图6可以看出,考虑相似日的预测曲线在波峰和波谷处更加贴合真实负荷曲线。结果说明,考虑相似日后能够为模型提供更高质量的输入,提高模型的拟合精度。




图6 考虑和不考虑相似日的模型预测结果对比

Fig. 6 Comparison of forecast results with and without similar days

为了验证IWOA-BiLSTM相较于基本方法的预测效果,将IWOA-BiLSTM和BP、LSTM、BiLSTM进行对比实验,预测结果如表3所示。

表3 不同模型的预测结果

Tab. 3 Prediction results of different models

预测模型	RMSE/MW	MAPE/%	$R^2$
BP	232.211	2.750	0.816
LSTM	206.447	2.411	0.854
BiLSTM	192.475	2.154	0.873
IWOA-BiLSTM	127.649	1.186	0.944

由表3可知,IWOA-BiLSTM模型相较于BiLSTM、LSTM和BP的RMSE误差分别降低了64.826、78.798和104.562 MW,MAPE误差分别降低了44.9%、50.8%和56.9%,决定系数 $R^2$ 分别提升了8.1%、10.5%和15.6%。根据以上分析可知,IWOA-BiLSTM的预测精度相较于基础模型更高,说明IWOA算法能够有效提升模型的预测精度。由图7可以看出,IWOA-BiLSTM的预测曲线在负荷的上升沿和下降沿都更加逼近真实负荷曲线,并且在10至30负荷波动较大的区间内的负荷预测效果更好。

为进一步验证IWOA算法的超参数寻优效果,分别使用WOA、IWOA和PSO算法对BiLSTM进行超参数优化。寻优算法的基本参数设置:种群个数设置为50,IWOA的控制参数初始值为2,终止值为




图7 不同模型的预测结果

Fig. 7 Prediction results of different models

1,非线性控制系数 $\mu$ 设置为2;PSO算法的粒子迭代最大速度设置为0.05。PSO-BiLSTM、WOA-BiLSTM和IWOA-BiLSTM三种预测模型的预测结果见表4。

表4 不同优化算法下的模型预测结果对比

Tab. 4 Comparison of model prediction results under different optimization algorithms

预测模型	RMSE/MW	MAPE/%	$R^2$
PSO-BiLSTM	163.805	1.718	0.908
WOA-BiLSTM	144.485	1.470	0.929
IWOA-BiLSTM	127.649	1.186	0.944

由表4可知,本文提出的IWOA-BiLSTM预测模型的预测精度最高,RMSE为127.649 MW,MAPE为1.186%, $R^2$ 为0.944,相比于PSO-BiLSTM和WOA-BiLSTM预测模型的RMSE误差指标分别降低了36.156 MW和16.836 MW;MAPE分别降低了31.0%和19.3%;决定系数分别提升了3.9%和1.5%,说明IWOA算法对BiLSTM的超参数寻优效果更好,对模型的预测准确度具有更好的提升效果。不同优化算法下的模型预测曲线图如图8。




图8 不同优化算法下的模型预测结果对比

Fig. 8 Comparison of model prediction results under different optimization algorithms

由图8可以看出,IWOA-BiLSTM的拟合效果最好,最接近真实值,并且在负荷波动处的曲线更贴合真实负荷曲线,PSO-BiLSTM和WOA-BiLSTM模型也能拟合处负荷的大致变化趋势,但在波峰波谷处偏离真实负荷曲线较远,BiLSTM的预测曲线的误差较大,出现较大的偏移。

为了验证不同改进策略下的IWOA-BiLSTM预测模型的预测效果,分别采用非线性控制参数和种群变异进行对比消融实验分析(表5).

表5 不同模型的预测结果对比

Tab. 5 Prediction results of different models

预测模型	改进策略	RMSE/MW	MAPE/%	$R^2$
IWOA-BiLSTM (method1)	非线性控制参数	135.710	1.385	0.937
IWOA-BiLSTM (method2)	种群变异	132.578	1.251	0.940
IWOA-BiLSTM (method3)	非线性控制参数+种群变异	127.649	1.186	0.944

由表5可知,非线性控制参数策略和种群变异策略对模型的预测精度有不同程度的提升,同时采用两种改进策略的IWOA-BiLSTM(method3)相较于method1和method2的MAPE误差分别降低了14.4%和5.1%,验证了两种改进策略能够有效提升模型的预测精度.由图9可知,IWOA-BiLSTM(method3)在10至30预测点间的预测曲线更加逼近真实负荷曲线,拟合效果更好.




图9 不同模型的预测结果对比

Fig. 9 Prediction results of different models

## 4 结语

本文提出了一种基于相似日和IWOA-BiLSTM的短期电力负荷预测模型,并通过真实负荷数据集进行了实验分析,得出以下结论:

(1)利用Pearson相关性分析选取主要影响因素,然后采用综合匹配相似度选取相似日,为模型提供更加有效的训练数据,有效提升了IWOA-BiLSTM的预测性能.

(2)采用IWOA算法对BiLSTM进行超参数优化,能够有效提升模型的预测精度,相比于BiLSTM、PSO-BiLSTM和WOA-BiLSTM获得了更好的预测效果.

(3)由仿真实验结果可知,本文提出的预测模

型的负荷预测结果更加逼近真实负荷曲线,并且在负荷波动处也有较好的拟合效果.

## 参考文献

- [1] 唐贤伦,陈洪旭,熊德意,等.基于极端梯度提升和时间卷积网络的短期电力负荷预测[J].高电压技术,2022,48(8):3059-3067.
- [2] 王晓佩,王琼.一种基于RBF自适应神经模糊推理的短期电力负荷预测方法[J].中南民族大学学报(自然科学版),2018,37(3):112-115.
- [3] PEI S Q, QIN H, YAO L Q, et al. Multi-step ahead short-term load forecasting using hybrid feature selection and improved long short-term memory network[J]. Energies, 2020, 13(16): 4121
- [4] 张宇帆,艾芊,林琳,等.基于深度长短时记忆网络的区域级超短期负荷预测方法[J].电网技术,2019,43(6):1884-1892.
- [5] 彭文,王金睿,尹山青.电力市场中基于Attention-LSTM的短期负荷预测模型[J].电网技术,2019,43(5):1745-1751.
- [6] MUZAFFAR S, AFSHARI A. Short-term load forecasts using LSTM networks[J]. Energy Procedia, 2019, 158: 2922-2927.
- [7] GUO X F, ZHAO Q N, ZHENG D, et al. A short-term load forecasting model of multi-scale CNN-LSTM hybrid neural network considering the real-time electricity price[J]. Energy Reports, 2020, 6: 1046-1053.
- [8] DOLATABADI A, ABDELTAWAB H, MOHAMED Y A R I. Hybrid deep learning-based model for wind speed forecasting based on DWPT and bidirectional LSTM network[J]. IEEE Access, 2020, 8: 229219-229232.
- [9] WANG S X, WANG X, WANG S M, et al. Bi-directional long short-term memory method based on attention mechanism and rolling update for short-term load forecasting [J]. International Journal of Electrical Power & Energy Systems, 2019, 109: 470-479.
- [10] 任建吉,位慧慧,邹卓霖,等.基于CNN-BiLSTM-Attention的超短期电力负荷预测[J].电力系统保护与控制,2022,50(8):108-116.
- [11] 张淑清,李君,姜安琦,等.基于FPA-VMD和BiLSTM神经网络的新型两阶段短期电力负荷预测[J].电网技术,2022,46(8):3269-3279.
- [12] 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.
- [13] 曹杰,王维庆,王海云,等.基于改进PSO-LSSVM的电采暖短期负荷预测研究[J].计算机仿真,2022,

- 39(2): 34-39.
- [14] 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.
- [15] 高丽玲, 李媛, 龙洋. 参数优化的舰船短期电力负荷预测模型[J]. 舰船科学技术, 2021, 43(6): 112-114.
- [16] ZENG N Y, ZHANG H, LIU W B, et al. A switching delayed PSO optimized extreme learning machine for short-term load forecasting[J]. Neurocomputing, 2017, 240: 175-182.
- [17] WANG H Y, LV X H, LUO X N. Short-term load forecasting of power grid based on improved WOA optimized LSTM[C]//2020 5th International Conference on Power and Renewable Energy (ICPRE). Shanghai: IEEE, 2020: 54-60.
- [18] SHANG Z H, HE Z S, SONG Y R, et al. A novel combined model for short-term electric load forecasting based on whale optimization algorithm[J]. Neural Processing Letters, 2020, 52(2): 1207-1232.
- [19] 邢光林, 胡露蓉. 基于改进鲸鱼优化算法的水声传感器网络分簇路由方法[J]. 中南民族大学学报(自然科学版), 2025, 44(2): 213-219.
- [20] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.

(责编&校对 姚春娜)