

# 基于 WOA-BiLSTM 模型的电力负荷预测

蓝俊欢<sup>1</sup>, 宋倩<sup>2\*</sup>

(1. 广西电网有限责任公司河池供电局, 广西 河池 546300;

2. 河池学院大数据与计算机学院, 广西 河池 546300)

**摘要** 本文针对传统负荷预测方法难以满足新型电力系统背景下负荷模式的问题, 提出了基于 WOA 算法优化 BiLSTM 的短期电力负荷预测方法。BiLSTM 可利用前后向的神经网络结构, 加强电力负荷数据的记忆能力, 提高预测精度。WOA 算法可凭借气泡网捕食方法, 协助 BiLSTM 训练时找到最优网络参数。将 WOA-BiLSTM 模型应用于某地区的电力负荷预测, 结果表明, 相较于 BP、LSTM、BiLSTM, 所提方法预测精度和收敛速度是最好的, 能为新型电力系统的规划、运行、控制及调度提供可靠依据。

**关键词** 电力负荷预测; WOA 算法; BiLSTM

**基金项目:** 2022 年广西高校中青年教师科研基础能力提升项目 (2022KY0606)、2023 年河池学院校级科研平台 (2023XJPT011)。

**中图分类号:** TM74

**文献标识码:** A

**文章编号:** 2097-3365(2024)04-0004-03

电力负荷预测是电力系统供需形势分析的根本, 高效且精准预测电力负荷既有助于电力能源的合理分配, 又能实时监控电力供需平衡, 从而保障电力系统安全稳定运行<sup>[1]</sup>。短期电力负荷预测是电力负荷预测的重要组成部分, 它是对未来某一时间段内各个时刻的用电负荷值的预测<sup>[2]</sup>。而今, 学者们对电力负荷预测做了大量研究, 又将 CNN 与 BiLSTM 组合构建了 CNN-BiLSTM 预测模型<sup>[3]</sup>; BiLSTM 模型是对单向 LSTM 网络的扩展, 具备双向时序特征, 与 LSTM 和 CNN-LSTM 相比, CNN-BiLSTM 提升预测的精度更优<sup>[4]</sup>。另外, 将 LSTM 与 XGBoost 模型组合进行预测, 预测精度均高于单一预测模型<sup>[5]</sup>。鉴于 BiLSTM 的优势, 结合已有研究成果, 本文提出一种基于 WOA-BiLSTM 的电力负荷预测方法。首先, WOA 算法对 BiLSTM 模型进行优化, 找到最优网络参数。然后传参给 BiLSTM 模型进行预测。最后, 通过广西某地区的电力实测值进行实验, 检验所提方法的有效性。

## 1 预测模型的基本原理

### 1.1 BiLSTM 原理

BiLSTM 采用正向 LSTM 层和反向 LSTM 层相连接, 同时提取过去和未来的隐藏层信息来实现对当前时刻的预测, 从而提升模型的预测精度。电力负荷数据在单向 LSTM 网络中训练按从前往后进行, 训练方式对数据利用率低, 难以充分挖掘数据内在特征。而 BiLSTM

双向网络对过去和未来的隐藏层状态进行递归传播, 使信息提取更充分, 因而 BiLSTM 模型预测精度更精准。其网络结构如图 1 所示。

### 1.2 WOA 算法原理

WOA 是一种模拟座头鲸围捕猎物行为的群体智能优化算法<sup>[6]</sup>, 主要包含包围猎物、气泡网攻击和搜索猎物三大过程。

1. 包围猎物: 鲸鱼先确定目标猎物范围, 即局部最优的捕食方向, 设置好最优猎物位置进行包围, 位置更新如公式 (1)、(2):

$$X(t+1) = X^*(t) - A \cdot D_1 \quad (1)$$

$$D_1 = |C \cdot X(t) - X(t)| \quad (2)$$

式中,  $X$  为鲸鱼位置向量;  $X^*$  为当前最优猎物的位置向量;  $t$  为当前迭代轮数;  $A \cdot D_1$  为鲸鱼到猎物的距离。其中,  $A$  和  $C$  为系数向量, 作用是控制鲸鱼的移动方式, 可通过公式 (3) - (5) 计算得出。

$$A = 2ar - a \quad (3)$$

$$C = 2r \quad (4)$$

$$a = 2 - \frac{2t}{t_{\max}} \quad (5)$$

式中,  $a$  为从 2 线性减少到 0 的收敛因子;  $r$  为  $[0, 1]$  之间的随机数;  $t_{\max}$  为当前迭代的最大值。

2. 起泡网攻击: 鲸鱼在攻击时有收缩包围机制和螺旋更新位置机制两种<sup>[7]</sup>。本文假设两种机制各占 0.5

\*本文通讯作者, E-mail: 1711563632@qq.com。

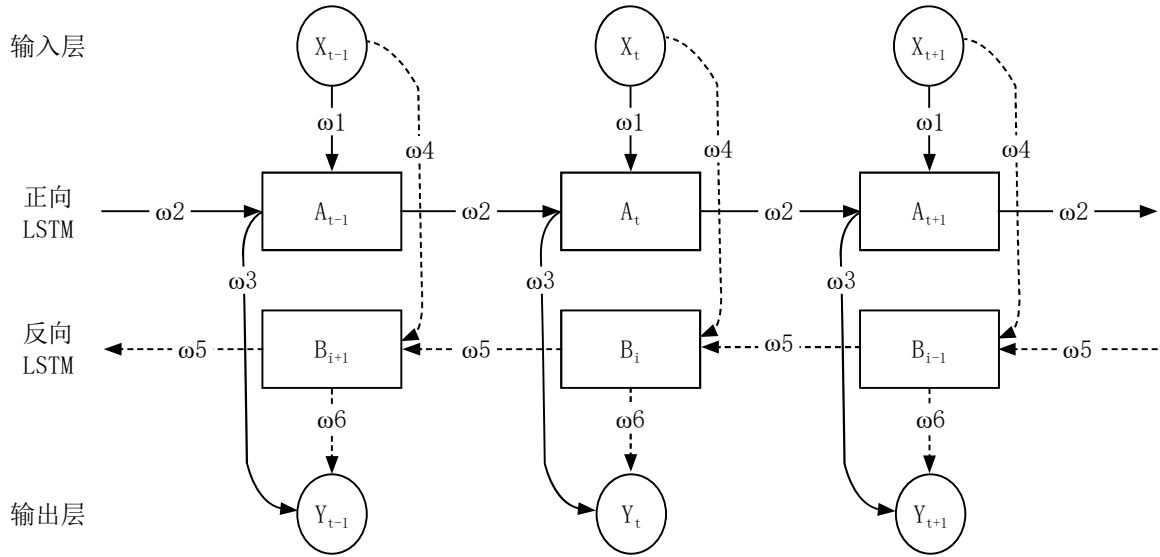


图 1 BiLSTM 网络结构图

的概率, 鲸鱼更新位置如公式 (6)、(7):

$$\text{当 } p < 0.5 \text{ 时, } X(t+1) = X^*(t) - A \cdot D_1 \quad (6)$$

当 \$p > 0.5\$ 时,

$$X(t+1) = X^*(t) + D_2 \cdot e^{bl} \cdot \cos 2\pi l \quad (7)$$

3. 搜索猎物: 当 \$|A| < 1\$ 时, 鲸鱼开始攻击包围猎物; 当 \$|A| > 1\$ 时, 鲸鱼随机探索新位置, 然后选择新的猎物, 随机寻优如公式 (8)、(9):

$$X(t+1) = X_{rd}(t) - A \cdot D_{rd} \quad (8)$$

$$D_{rd} = |C \cdot X_{rd}(t) - X(t)| \quad (9)$$

## 2 WOA-BiLSTM 组合预测模型

### 2.1 WOA 优化 BiLSTM 算法流程

首先, 对原始数据进行预处理, BiLSTM 模型读取数据集中的数据。其次, WOA 初始化种群参数, 设置鲸鱼总群位置上下界、种群数量和鲸鱼个体空间维度。然后传给 BiLSTM 模型, 输入训练集进行训练, 在测试集中预测, 得出真实值和预测值间的误差。最后, WOA 算法不断迭代, 参数继续传给 BiLSTM 模型进行再训练, 直到找到最优网络超参数和最优解传递给模型。算法流程如图 2 所示。

### 2.2 数据预处理及误差指标

#### 2.2.1 数据归一化

本文选用广西某地区的实际电力 2014 年 1 月 1 日—2015 年 1 月 10 日共 1 年 10 天的负荷数据, 一天采集 96 个样本点, 时间间隔为 15min。采用最小—最大标准化将数据归一化到 \$[0, 1]\$, 计算如公式 (10) 所示。

$$y_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中, \$X\_i\$ 是第 \$i\$ 个时间点的负荷数据; \$y\_i^\*\$ 是 \$X\_i\$ 归一化后的值; \$X\_{\max}\$ 和 \$X\_{\min}\$ 分别为实测数据中的最大值和最小值。当归一化后, 利用公式 (11) 对其进行反归一化。

$$x^* = y_i^* (x_{\max} - x_{\min}) + x_{\min} \quad (11)$$

式中, \$y\_i^\*\$ 为归一化的预测值; \$x^\*\$ 为反归一化的预测值。

#### 2.2.2 误差评价指标

本文采用 mape、rmse、mae 来评价预测模型的性能。mape、rmse 及 mae 的值越小, 代表负荷预测越准确, 指标计算如公式 (12) - (14) 所示。

$$mape = \frac{1}{n} \sum_{i=1}^n \left| \frac{y(t) - y^*(t)}{y(t)} \right| \quad (12)$$

$$rmse = \sqrt{\frac{1}{n} \sum_{i=1}^n (y(t) - y^*(t))^2} \quad (13)$$

$$mae = \frac{1}{n} \sum_{i=1}^n |y(t) - y^*(t)| \quad (14)$$

式中, \$y(t)\$ 为 \$t\$ 时刻真实负荷值; \$y^\*(t)\$ 为 \$t\$ 时刻预测负荷值; \$n\$ 为负荷数据总数。

## 3 WOA-BiLSTM 模型预测结果分析

### 3.1 各个神经网络模型对比

将选取的数据分别输入 BP、LSTM、BiLSTM 模型中, 依次对 1 月 9 日和 1 月 10 日的负荷进行预测, BiLSTM 较 BP 在 mape、rmse、mae 降低了 0.6097%、30.64MW、0.2370%, 较 LSTM 在 mape、rmse、mae 也降低了 0.0267%、1.22MW、0.0098%, BiLSTM 模型较 BP、LSTM 模型有更好的预测性能。如表 1 所示。




图2 WOA-BiLSTM算法流程图

表1 各个神经网络模型的评价指标

模型	mape	rmse	mae
BP	0.8731	38.86	0.3032
LSTM	0.2901	9.44	0.0740
BiLSTM	0.2634	8.22	0.0642

### 3.2 WOA 优化 BiLSTM 前后对比

利用 WOA 对模型参数进行优化后, mape 降低了 0.0541%, rmse 减少了 30.9MW, 表明 WOA 算法能为 BiLSTM 寻到较优的参数, 模型预测效果更好。如表 2 所示。

表2 WOA 优化前后误差对比

模型	mape	rmse	mae
BiLSTM	0.2634	82.2	0.0642
WOA-BiLSTM	0.2093	51.3	0.0407

## 4 结论

本文构建 WOA-BiLSTM 的短期电力负荷预测模型, 其优势在于: 既考虑了温度、湿度、降雨量等多维因素对负荷预测的影响, 从而提升了待测日的预测精度,

又应用 WOA 算法优化 BiLSTM 模型找到一组网络超参数, 实现了超参数的优化选择, 使预测精度更优。

## 参考文献:

- [1] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. 电力系统保护与控制, 2020, 48(21): 117-124.
- [2] KHURSHEED A, MUSAED A, KUMAIL J, et al. A pyramid-CNN based deep learning model for power load forecasting of similar-profile energy customers based on clustering[J]. IEEE Access, 2021(09): 14992-15003.
- [3] 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.
- [4] WU K, WU J, FENG L, et al. An attention based CNN-LSTM-BiLSTM model for short-term electric load forecasting in integrated energy system[J]. International Transactions on Electrical Energy Systems, 2021, 31(01): e12637.
- [5] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(02): 614-620.
- [6] 刘英, 裴莉莉, 郝雪丽. 基于 WOA-BiLSTM 模型的空气质量指数预测[J]. 计算机系统应用, 2022, 31(10): 389-396.
- [7] 同 [6].