

DOI: 10.19783/j.cnki.pspc.231402

基于 DBO-VMD 和 IWOA-BILSTM 神经网络 组合模型的短期电力负荷预测

刘杰¹, 从兰美¹, 夏远洋², 潘广源¹, 赵汉超¹, 韩子月¹

(1. 临沂大学自动化与电气工程学院, 山东 临沂 276002; 2. 雅砻江流域水电开发有限公司, 四川 成都 610000)

摘要: 新能源在现代电力系统中占比不断提高, 其负荷不规律性、波动性远大于传统电力系统, 这就导致负荷预测精度不高。针对这个问题, 提出了蜣螂优化(dung beetle optimizer, DBO)算法优化变分模态分解(variational mode decomposition, VMD)与改进鲸鱼优化算法优化双向长短期记忆(improved whale optimization algorithm-bidirectional long short-term memory, IWOA-BILSTM)神经网络相结合的短期负荷预测模型。首先利用 DBO 优化 VMD, 分解时间序列数据, 并根据最小包络熵对各种特征数据进行分类, 增强了分解效果。通过对原始数据进行有效分解, 降低了数据的波动性。然后使用非线性收敛因子、自适应权重策略与随机差分法变异策略增强鲸鱼优化算法的局部及全局搜索能力得到改进鲸鱼优化算法(improved whale optimization algorithm, IWOA), 并用于优化双向长短期记忆(bidirectional long short-term memory, BILSTM)神经网络, 增加了模型预测的精确度。最后将所提方法应用于某地真实的负荷数据, 得到最终相对均方根误差、平均绝对误差和平均绝对百分比误差分别为 0.0084、48.09、0.66%, 证明了提出的模型对于短期负荷预测的有效性。

关键词: 蜣螂优化算法; VMD; 改进鲸鱼算法; 短期电力负荷预测; 双向长短期记忆神经网络; 组合算法

Short-term power load prediction based on DBO-VMD and an IWOA-BILSTM neural network combination model

LIU Jie¹, CONG Lanmei¹, XIA Yuanyang², PAN Guangyuan¹, ZHAO Hanchao¹, HAN Ziyue¹

(1. School of Automation and Electrical Engineering, Linyi University, Linyi 276002, China;
2. Yalong River Basin Hydropower Development Co., Ltd., Chengdu 610000, China)

Abstract: The share of renewable energy in modern power systems is increasing, causing its load to fluctuate more erratically than in conventional power systems. This volatility leads to lower accuracy of load prediction. To address this issue, this paper introduces a short-term load prediction model combining the dung beetle optimization algorithm (DBO) with optimized variational mode decomposition (VMD) and an improved whale optimization algorithm to optimize bidirectional long short-term memory (IWOA-BILSTM) neural networks. The DBO is used to optimize the VMD, the time series data is decomposed, and various feature data are classified according to the minimum envelope entropy. This enhances the decomposition effect. The fluctuation of the data is reduced by effectively decomposing the original data. Then the whale optimization algorithm is improved using a nonlinear convergence factor, adaptive weight strategy and random difference variation strategy to enhance the local and global search ability of the whale optimization algorithm. Thus an improved whale optimization algorithm (IWOA) is obtained, and it is then used to optimize bidirectional long short-term memory (BILSTM) neural networks, increasing the accuracy of model predictions. Finally, this method is tested on real load data from a location, yielding favorable results. The resulting metrics for relative root mean square, mean absolute and mean absolute percentage errors are recorded at 0.0084, 48.09, and 0.66%, respectively. These outcomes verify the effectiveness of the proposed model in short-term load prediction.

This work is supported by the National Natural Science Foundation of China (No. 62103177).

Key words: dung beetle optimization (DBO) algorithm; VMD; improved whale algorithm; short-term electric load prediction; bidirectional long and short-term memory neural networks (BILSTM); combinatorial algorithms

基金项目: 国家自然科学基金项目资助(62103177)

0 引言

随着经济的快速发展,我国对电能的需求日益增长。新能源用电设备的快速增长不断影响着电力系统的稳定,电力系统稳定运行对国民经济的发展有着非常重要的影响。随着新能源在现代电力系统中占比不断提高,负荷序列中的波动性和非线性远大于传统电力系统,进一步加大了预测难度。时间序列法^[1]、模糊回归法^[2]、支持向量回归(support vector regression, SVR)^[3]等传统的预测方法,由于其本身的缺陷,导致其预测精度较低,无法满足不断升级的智能电网的负荷预测要求^[4]。

近年来,长短期记忆(long short-term memory, LSTM)网络因为在预测方面具有良好的性能被广泛应用在电力负荷预测领域^[5-7]。文献[8]将 LSTM 网络与前馈神经网络实验进行了比较,突出了 LSTM 模型对短期电力负荷预测的高预测能力和实用性,但 LSTM 是根据时间序列从前到后进行传播和训练的,由于这种训练方法无法充分挖掘和提取负荷特征的深层联系,因此在 LSTM 的基础上开发了双向长短期记忆(bidirectional long short-term memory, BILSTM)神经网络。文献[9]通过对比 BILSTM 模型与 LSTM 模型在时间序列分析中的预测能力,确定了 BILSTM 模型在预测电力负荷方面的优越性。与其他神经网络模型类似, BILSTM 模型由于一些因素(如隐藏层的神经元数量和学习率),导致其泛化性能有限且过于依赖经验值。对此,文献[10]使用遗传算法(genetic algorithms, GA)对 BILSTM 的神经元数量和学习率等参数进行优化,来对超短期光伏功率进行预测,改善了模型泛化能力,验证了该组合算法的有效性。文献[11]利用灰狼优化器(gray wolf optimizer, GWO)对 BILSTM 模型进行优化,得到了最优超参数,有效地提升了对非线性短期负荷数据预测的精度。文献[12]提出一种注意力机制与鲸鱼优化算法(whale optimization algorithm, WOA)相结合的方法来优化 BILSTM 神经网络的预测模型,并与常用的自回归差分移动平均模型(autoregressive integrated moving average model, ARIMA)进行了对比,通过对比预测结果和指标发现, WOA-BILSTM 模型对于短期负荷预测具有更好的结果。但是上述文献都没有对不规律的、波动性大的数据进行有效处理。

通过将原始信号进行分解,可以有效降低原始信号的非稳定性,该方法逐渐应用到了负荷预测领域。文献[13]使用变分模态分解对历史序列进行分解,并与门控循环单元(gated recurrent unit, GRU)相

结合进行初步预测,证明了该方法的适用性和准确性。文献[14]针对配台区负荷预测精度低的问题,提出一种结合变分模态分解(variational modal decomposition, VMD)、迭代自组织数据分析算法与深度信念网络的短期负荷预测方法。文献[15]为提升母线负荷预测的精确性与稳定性,针对母线负荷噪声,提出一种考虑 VMD 降噪优化和 LSTM 的母线负荷预测方法。文献[16]采用 VMD 将光伏功率时间序列分解为不同的模态,降低了数据的非平稳性,并解决了文献[17]提及的经验模态分解(empirical modal decomposition, EMD)在分解过程中存在的模态混叠问题。但在实际的分解过程中, VMD 受分解个数 K 与惩罚因子 α 的影响较大,在之前的应用中仅依靠经验给定参数,因此分解效果并不理想^[18]。

基于以上研究,本文提出基于蜣螂优化(dung beetle optimizer, DBO)算法优化变分模态分解 DBO-VMD 和 IWOA-BILSTM 相组合的短期电力负荷预测模型。该模型首先以最小包络熵为适应度函数使用 DBO 算法对 VMD 进行优化,寻找分解参数的最优组合;之后利用寻优后的 VMD 去噪能力分解原始负荷数据,弱化负荷序列的随机波动性对预测精度的影响;然后针对分解后的各分量分别建立基于 BILSTM 的预测模型。为了提高预测精度,引入 WOA 对 BILSTM 模型参数进行优化,并分别采用非线性收敛因子、自适应权重策略与随机差分法变异策略增强 WOA 的局部及全局搜索能力。本文的贡献及创新如下:

1) 以最小包络熵为适应度函数,采用 DBO 对 VMD 进行优化,降低了分解参数的随机性,增强了分解效果;

2) 使用非线性收敛因子、自适应权重策略与随机差分法变异策略增强 WOA 的局部及全局搜索能力,并用于优化 BILSTM 神经网络,提高了对短期负荷预测的精确度;

3) 用实际电力数据对上述方法进行了实验,证明了所提组合模型对短期负荷预测的有效性,并通过对比不同优化算法、不同组合模型证明了本文提出的模型的优越性。

1 蜣螂算法优化变分模态分解

1.1 变分模态分解

VMD 是一种新的、非递归的、完全内在的和自适应的信号处理工具,能够将信号分解为子信号或 IMFs^[19]。这些 IMFs 是原始信号的频谱分量,具有有限的带宽,并且在中心脉动周围紧凑。每个 IMF 表示原始信号在不同频率范围上的特性,通过组合

所有的 IMF, 可以重构原始信号。为了检测每个 IMF 的带宽和中心频率, VMD 采用进化变分问题的最优结果作为理论方案, 并迭代地保持恒定的优化策略。任何信号的分解问题都可以定义为

$$\begin{cases} \min_{(\omega_k, u_k)} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

式中: u_k 为第 k 个模态分量; ω_k 为第 k 个中心频率; $f(t)$ 为原始负荷序列; ∂_t 为偏导运算符; δ_t 为单位脉冲函数。

所有模式的总和重构了原始信号 $f(t)$ 。本文引入二次惩罚项 α 和拉格朗日乘子 λ 来解决信号重构过程中的这种约束变分, 式(1)可以修改为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (2)$$

在每次移位操作期间, 引入了乘法器的交替方向方法 (alternate direction method for multipliers, ADMMs), 以在每次移位过程中产生不同的模式和中心频率。使用 ADMMs 可以有效地最小化式(2), 相应地更新中心频率和频域中的估计模式显示, 如式(3)、式(4)所示。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

式中: $\hat{u}_k^{n+1}(\omega)$ 为当前余量的维纳滤波; ω_k^{n+1} 为当前模态分量的中心频率; $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 、 $\hat{u}_i(\omega)$ 分别为 $f(t)$ 、 $\lambda(t)$ 、 $u(t)$ 的傅里叶变换。

1.2 螭螂优化算法

DBO 是一种基于螭螂行为的新优化算法^[20], 具有收敛快速、高精度和高稳定性的特点。DBO 算法主要通过螭螂的位置变化获得全局最佳位置和适应度值, 具有跳舞、滚动、偷盗、觅食、繁殖等 5 种行为。假设 n 代表金龟郎的种群大小。

1) 螭螂向前方滚球时位置更新和定义

$$y_i^{t+1} = y_i^t + gGy_i^{t-1} + h|y_i^t - y_{\text{worst}}^t| \quad (5)$$

式中: y_i^t 为第 i 只螭螂迭代 t 次后所在的位置; g 为随机数-1 或 1; G 为(0,0.2)内的随机数; y_{worst}^t 为全局最差的位置; h 为(0,1)内的随机数。

2) 当螭螂遇到障碍物无法前进时, 它需要通过跳舞来重新调整自己, 以获得新的路线。

$$y_i^{t+1} = y_i^t + \tan \theta |y_i^t - y_i^{t-1}| \quad (6)$$

式中: θ 是 $[0, \pi]$ 内的随机数, 当 $\theta = 0, \frac{\pi}{2}, \pi$ 时, 螭螂位置无变化。

3) 螭螂繁殖过程

$$y_i^{t+1} = y_{\text{gbest}}^t + \mathbf{b}_1(y_i^t - L_b^*) + \mathbf{b}_2|y_i^t - U_b^*| \quad (7)$$

式中: \mathbf{b}_1 、 \mathbf{b}_2 均为是一个独立的 $1 \times b$ 维随机矩阵; L_b^* 、 U_b^* 分别为繁殖区域的上下界; y_{gbest}^t 是当前全局最佳位置。

4) 更新一只螭螂在觅食时的现有位置并将其定义为

$$y_i^{t+1} = y_i^t + \mathbf{C}_1(y_i^t - L_b^t) + \mathbf{C}_2|y_i^t + U_b^t| \quad (8)$$

式中: L_b^t 、 U_b^t 分别为觅食区域的上下界; \mathbf{C}_1 服从正态分布的 $1 \times d$ 维矩阵; \mathbf{C}_2 为 $1 \times d$ 维随机矩阵。

5) 一些螭螂会从其他螭螂那里偷粪球, 此时它们的位置更新公式为

$$y_i^{t+1} = y_{\text{lbest}}^t + Sg(|y_i^t - y_{\text{gbest}}^t| + |y_i^t - y_{\text{lbest}}^t|) \quad (9)$$

式中: g 是服从正态分布的 $1 \times d$ 矩阵; y_{lbest}^t 是局部最佳位置; S 是一个常数。

最后, 将滚球跳舞的螭螂分成一组, 将每种行为中剩下的螭螂单独分组。各组的位置根据其所属组的行为进行更新, 并进行多次迭代, 得到全局最佳位置及其适应度值。

1.3 DBO 优化 VMD

根据 VMD 过程和分解原理可以看出, 分解的数量 K 和惩罚因子 α 对结果有显著影响。本文以最小包络熵 E_p 作为适应度函数, 利用 DBO 对 VMD 参数进行了优化, 公式为

$$E_p = -\sum_{j=1}^m p_j \log_{10} p_j \quad (10)$$

其中

$$p_j = a(j) / \sum_{j=1}^m a(j) \quad (11)$$

式中: p_j 表示一个事件发生的概率; m 为样本数; $a(j)$ 为由 VMD 模态分量的希尔伯特解调包络序列。

DBO 优化 VMD 的流程图如图 1 所示。

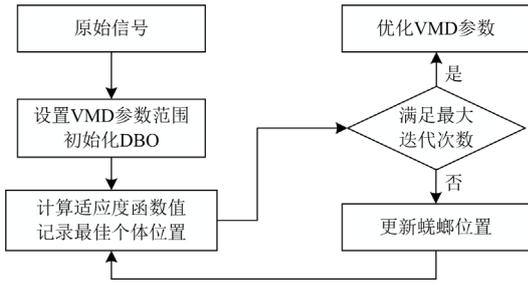


图1 DBO 优化 VMD 流程图

Fig. 1 Flow chart of DBO optimizing VMD

2 双向长短期记忆神经网络

一般的循环神经网络(recurrent neural network, RNN)^[21]没有记忆过去数据的能力。LSTM 是一种特殊类型的 RNN 模型,可以解决梯度消失问题^[22]。LSTM 神经网络包含多个循环单元,其中输入门 i_t 决定输入到当前时刻单元状态 C_t 的数据量;遗忘门 f_t 操控记忆单元,决定上一时刻的单元状态 C_{t-1} 数据量的保留,是 LSTM 实现长期记忆的保证;输出门 o_t 决定单元状态数据量的输出。整个网络单元的状态更新如图 2 所示。

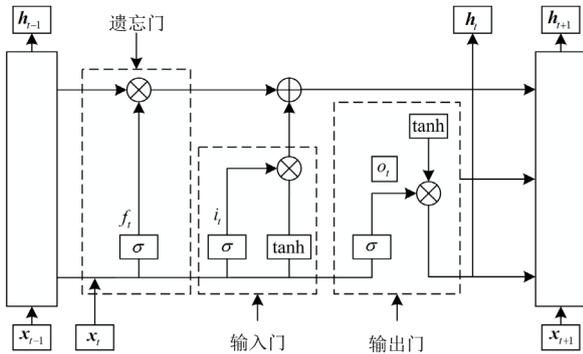


图2 LSTM 基本单元结构

Fig. 2 Basic unit structure of LSTM

遗忘门:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (12)$$

输入门:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (13)$$

$$C'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (14)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t \quad (15)$$

输出门:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t \odot \tanh(C_t) \quad (17)$$

式中: W_f 、 W_i 、 W_o 、 W_c 分别为对应门的权值矩阵; b_f 、 b_i 、 b_o 、 b_c 分别为对应门的偏置项; C'_t 为

输出层单元状态; h_t 、 h_{t-1} 分别为 t 、 $t-1$ 时刻隐藏状态向量; σ 为 Sigmoid 激活函数; \odot 为 Hadamard 积; $[]$ 为向量连接。

LSTM 模型在双向长短期记忆网络中得到了扩展^[23]。对于 BILSTM, 输入数据由两个 LSTM 处理, 输入序列(即前向层)首先在第一轮中受到 LSTM 的应用, 然后在第二轮中, LSTM 模型的后向层再以反向形式得到输入序列。通过两次应用 LSTM, 学习的长期依赖性得到改善, 从而提高了模型的准确性。为了从更多角度学习序列特征信息, 双向输入收集了前向和后向的序列特征信息, BILSTM 结构如图 3 所示。

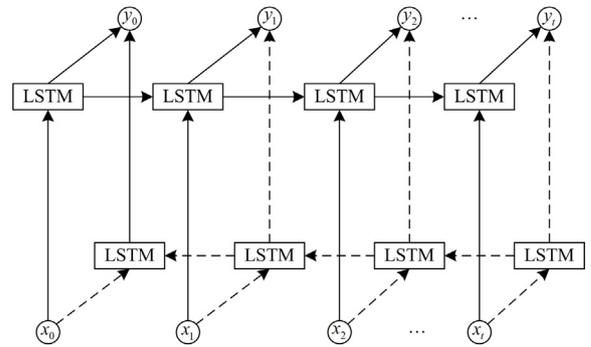


图3 BILSTM 结构图

Fig. 3 BILSTM structure diagram

3 改进鲸鱼优化算法

3.1 鲸鱼优化算法

WOA 由 Jalili 和 Lewis 提出, 用于优化数值问题^[24], 该算法模拟了座头鲸的智能狩猎行为, 这种觅食行为被称为气泡网摄食方法, 只能在座头鲸中观察到。在捕猎过程中, 鲸鱼在环绕猎物时沿着圆形路径形成典型的气泡, 数学模型如下所述。

1) 包围猎物

当群体中的一头或多头座头鲸找到所需的猎物时, 它们会提醒群体中的其他成员将猎物包围起来, 可表达为

$$D = |C \cdot X_p(t) - X(t)|, X(t+1) = X_p(t) - A \cdot D \quad (18)$$

式中: A 、 C 为系数向量; $X(t)$ 为鲸鱼位置向量; $X_p(t)$ 为猎物位置; D 为鲸鱼与猎物的距离向量。

$$A = 2a \cdot r_1 - a, C = 2 \cdot r_2 \quad (19)$$

$$a = 2 - \frac{2t}{T_{\max}} \quad (20)$$

式中: r_1 和 r_2 为 $[0,1]$ 区间的随机数; a 为线性收敛因子; T_{\max} 为最大迭代次数。

2) 进攻猎物

当模拟鲸鱼找到猎物时,通过螺旋式上升不断缩小其距离以实施围攻,同时将猎物的位置传达给其他伙伴。这个过程表示为

$$\mathbf{X}(t+1) = \mathbf{D} \cdot e^{bl} \cdot \cos(2\pi l) + \mathbf{X}_p(t) \quad (21)$$

$$\mathbf{X}(t+1) = \begin{cases} \mathbf{X}_p(t) - \mathbf{A} \cdot \mathbf{D} & 0 \leq p < 0.5 \\ \mathbf{D} \cdot e^{bl} \cdot \cos(2\pi l) + \mathbf{X}_p(t) & 0.5 \leq p \leq 1 \end{cases} \quad (22)$$

式中: l 是范围为 $[0,1]$ 内的随机数; p 为 $[0,1]$ 内的随机值; 常数 b 代表运动轨迹。

3) 捕获进食

几乎所有的元启发式算法都是通过随机选择来探索最优方案的。在气泡网中,最佳设计的位置是未知的,因此座头鲸会随机地寻找猎物。与开发阶段不同的是,搜索代理的位置将根据搜索代理随机选择的值更新,而不是根据迄今为止发现的最佳搜索代理的位置进行更新,其表达式为

$$\mathbf{D} = |\mathbf{C} \cdot \mathbf{X}_{\text{rand}}(t) - \mathbf{X}(t)|, \mathbf{X}(t+1) = \mathbf{X}_{\text{rand}}(t) - \mathbf{A} \cdot \mathbf{D} \quad (23)$$

式中, \mathbf{X}_{rand} 为随机鲸鱼个体的位置向量。

3.2 改进鲸鱼优化算法

对于 WOA, 系数向量 \mathbf{A} 用于调整全局搜索和本地利用功能。从式(19)中可以明显看出, \mathbf{A} 随线性收敛因子 a 的变化而变化, 因此, 在优化过程中 WOA 的全局搜索和利用能力的转换取决于 a , 从式(20)可以看出, 随着迭代次数 t 的不断增加, a 会从 2 线性地减小到 0。WOA 的优化过程比较复杂, 并不是线性变化, 因此 a 的线性更新策略不能完全反映实际情况, 对此, 本研究引入了一个非线性收敛因子^[25], 公式为

$$\hat{a} = 2 - 2\sin\left(\mu \frac{t}{T_{\max}} \pi + \varphi\right) \quad (24)$$

式中, μ 和 φ 为相关参数。

3.3 自适应权重策略与随机差分法变异策略

当鲸鱼优化算法到后期局部开发时,收敛精度会逐渐变低,并且容易陷入局部最优解。此时,为了提高收敛精度并使算法及时跳出局部最优,采用自适应权重策略^[26-27]和随机差分变异策略^[28-29]对其进行优化。

自适应权重策略数学表达式为

$$\omega = 1 - \frac{e^{\frac{1}{T_{\max}} - 1}}{e - 1}, \mathbf{X}(t+1) = \omega \cdot \mathbf{X}_p(t) - \mathbf{A} \cdot \mathbf{D} \quad (25)$$

$$\mathbf{X}(t+1) = \omega \cdot \mathbf{X}_p(t) + \mathbf{D} \cdot e^{bl} \cdot \cos(2\pi l) \quad (26)$$

随机差分变异策略为

$$\mathbf{X}(t+1) = r_1 \times (\mathbf{X}_p(t) - \mathbf{X}(t)) + r_2 \times (\mathbf{X}'(t) - \mathbf{X}(t)) \quad (27)$$

式中, $\mathbf{X}'(t)$ 为种群中随机个体。

为了加快种群收敛速度,防止种群陷入局部最优,在进行包围捕食或者螺旋式更新时,每个鲸鱼个体都会进行两次位置更新。首先根据自适应权重进行第一次位置更新。第一次位置更新后再根据随机差异变化策略进行第二次位置更新,以获取其变化前后的最佳位置。这两种策略相互补充,提高了算法种群寻找最优解的能力^[30]。

综上所述,对 WOA 进行如下改进:

1) 形成鲸群,包含随机产生的 N 个鲸鱼个体,并对参数初始化。

2) 在解空间中利用准反向学习初始化种群,同时令 $t=1$ 。

3) 进行判断,当 $t \geq T_{\max}$ 时,输出最优解;当 $t < T_{\max}$ 时,计算每个个体的适应度值并记录最优个体位置。

4) 根据式(24)计算 \hat{a} 的值,根据式(19)更新系数向量 \mathbf{A} 和 \mathbf{C} 。

5) 随机生成一个 $[0,1]$ 内的值 p ,不同个体与猎物位置更新情况如式(28)所示。

$$\begin{cases} p < 0.5 & \begin{cases} |\mathbf{A}| < 1 & \text{根据式(25)更新位置} \\ |\mathbf{A}| \geq 1 & \text{根据式(23)更新位置} \end{cases} \\ p \geq 0.5 & \text{根据式(26)更新位置} \end{cases} \quad (28)$$

6) 根据式(27)对种群进行随机差分变异扰动,令 $t=t+1$ 。

7) 当迭代次数接近预定的最大值时,输出最终的优化参数,否则,回到第 2)步,进行 $t=t+1$ 次迭代。

本文提出的基于 DBO-VMD 和 IWOA-BILSTM 神经网络组合的短期电力负荷预测模型如图 4 所示。

4 仿真实验

算例数据来源于某电网提供的真实电力负荷数据,采样数据时间跨度为 2012 年 3 月 1 日至 5 月 31 日,每 15 min 采样一次,全天 96 次,共计 8832 个负荷数据点,原始负荷数据如图 5 所示。将负荷数据前 8160 条作为模型训练样本,后 672 条作为测试样本,并与实际负荷进行对比。本文算法均使用 Matlab2023a 环境实现。并用多种预测模型与本文提出的 DBO-VMD-IWOA-BILSTM 模型进行了对比实验。

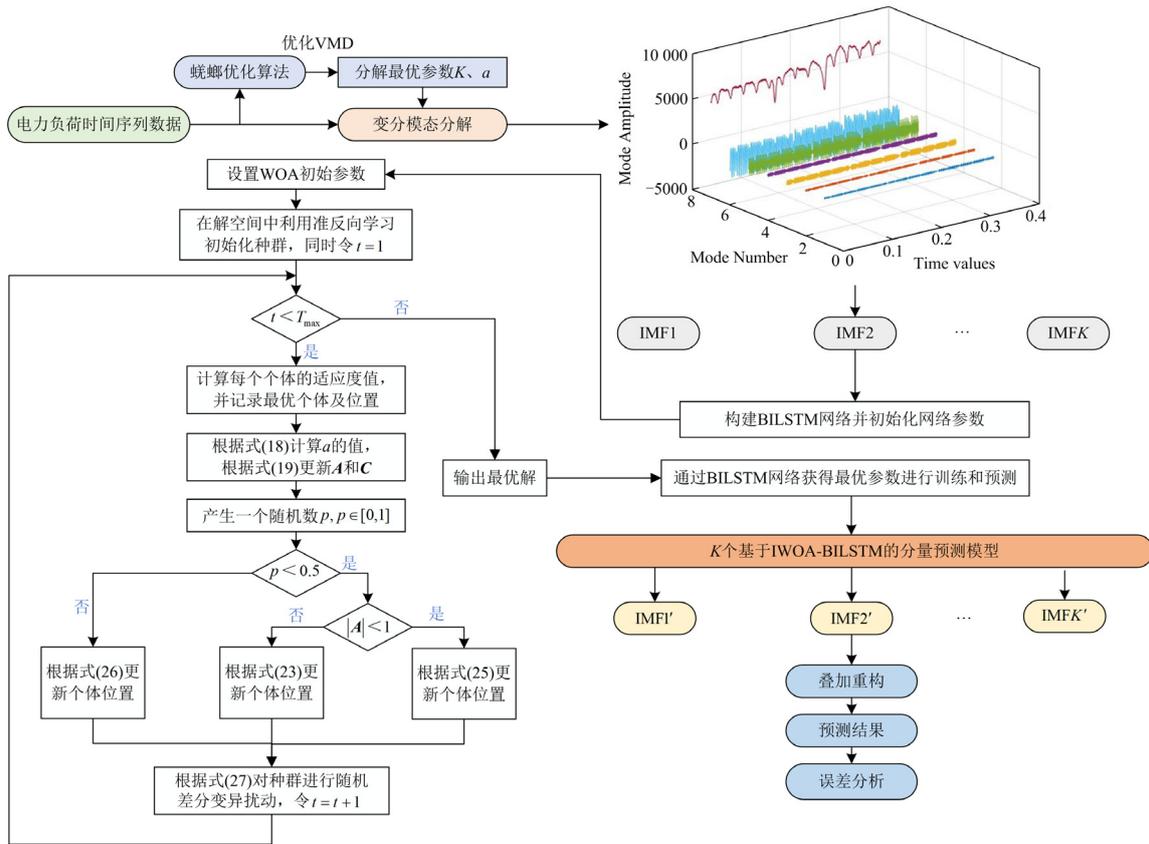


图 4 基于 DBO-VMD-IWOA-BILSTM 神经网络的短期负荷预测模型

Fig. 4 Short-term load forecasting model based on DBO-VMD-IWOA-BILSTM neural network

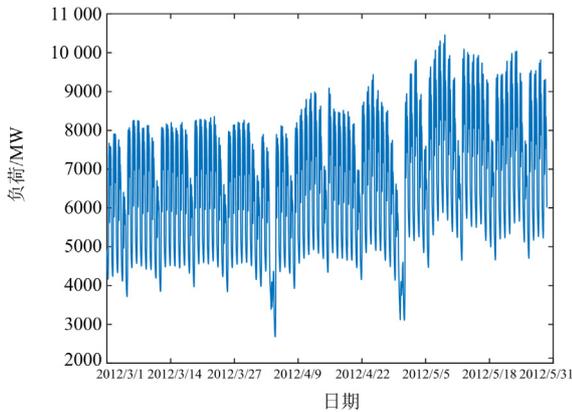


图 5 原始负荷数据

Fig. 5 Raw load data

4.1 数据预处理及评价指标

为消除不同量纲的影响, 对 VMD 后的序列分别进行标准化处理, 标准化公式为

$$X' = \frac{X - \mu}{\sigma} \quad (29)$$

式中: X 为原始数据; X' 为标准化后的数据; μ 、 σ 分别为原始样本数据的均值和标准差。

为对比分析, 实验选择的评估指标是相对均方根误差 (relative root mean square error, RRMSE) E_{RRMSE} 、平均绝对误差 (mean absolute error, MAE) E_{MAE} 和平均绝对百分比误差 (mean absolute percentage error, MAPE) E_{MAPE} 。这 3 个指标的计算公式为

$$E_{RRMSE} = \frac{\sqrt{\frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{m}}}{\text{mean}(y_i)} \quad (30)$$

$$E_{MAE} = \frac{1}{m} \sum_{i=1}^m |(y_i - \hat{y}_i)| \quad (31)$$

$$E_{MAPE} = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (32)$$

式中: y_i 为负荷的真实值; \hat{y} 为模型负荷预测值; m 为测试样本的总数。

4.2 DBO-VMD

采用 DBO-VMD 对电力负荷数据进行分解, 来降低电力负荷的随机性和波动性, 使用 DBO 以最小包络熵为适应度函数对分解的数量 K 和惩罚因子 α 进行寻优, 参数设置如表 1 所示。

表 1 DBO 参数设置

Table 1 DBO parameter settings

α	K	优化变量数	最大迭代数	种群数
[100 2500]	[2 10]	2	20	25

DBO-VMD 的寻优过程如图 6 所示, 可以看出迭代次数为 3 时趋于稳定, 此时求得最优分解数量 $K=7$, 最优惩罚因子 $\alpha=1839$ 。

VMD 参数设置如表 2 所示。

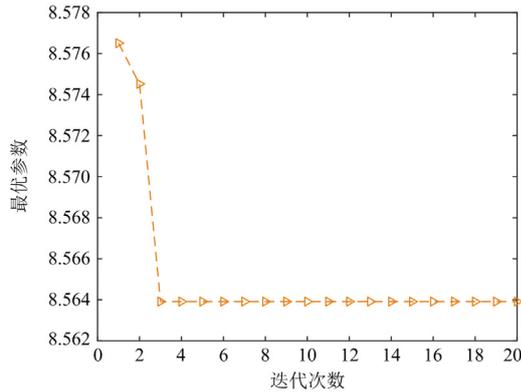


图 6 DBO-VMD 的寻优过程

Fig. 6 DBO-VMD optimization process

表 2 VMD 参数设置

Table 2 VMD parameter settings

分解个数 K	惩罚因子 α	中心频率 ω	收敛判据 r
7	1839	0	10^{-7}

经 DBO-VMD 得到的残差与 7 个不同的模态分量如图 7 所示。

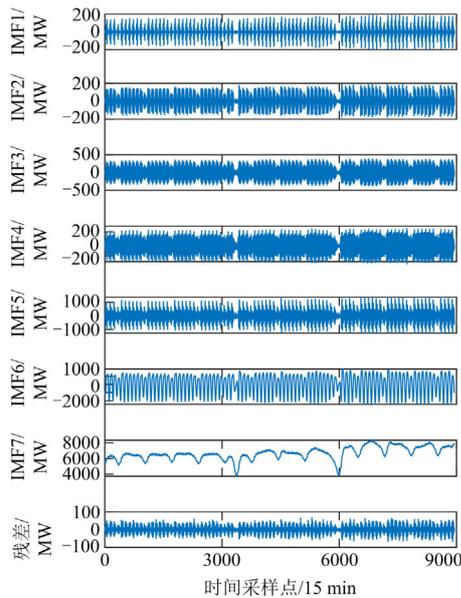


图 7 各模态分量与分解残差

Fig. 7 Components and decomposition residuals of each mode

重构后的数据与原始负荷对比如图 8 所示。

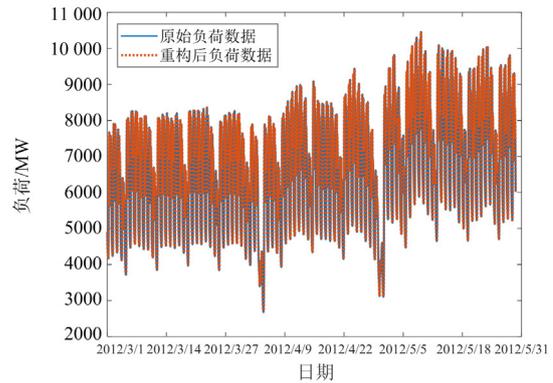


图 8 重构后的数据与原始负荷对比

Fig. 8 Comparison of the reconstructed data with the original data

4.3 DBO-VMD-IWOA-BILSTM 的预测效果分析

为体现本文所用优化算法的优越性, 将 IWOA、DBO、WOA、GA 进行了适应度对比实验, 各优化器参数统一设置: searchagents = 30; numm = 11; smax_iterations = 1000。并在使用 CEC2005 函数测试集的测试中对智能算法性能挑战较大的 F5、F8 函数作对比, 结果如图 9 所示。

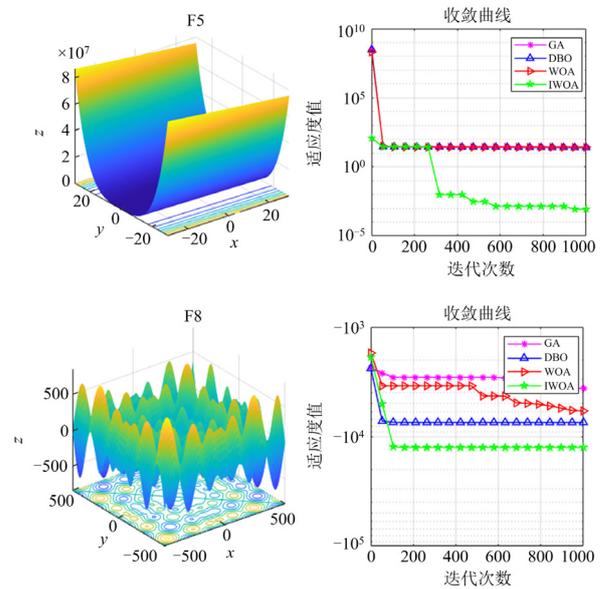


图 9 4 种优化器性能对比

Fig. 9 Comparison of the performance of the four optimizers

由图 9 可以看出, IWOA 与 DBO 相对于 GA 收敛速度更快, 且对于理论最小值为 -12 569.5 的 F8 函数来说, IWOA 对 F8 函数的寻优值为 -12 569.4737, 更能接近理论值。

本文使用 IWOA 优化 BILSTM 模型中的隐藏单

元数、训练周期、L2Regularization 以及学习率等参数, 通过网格搜索的方法进行超参数优化, 实验采用的超参数选取情况如表 3 所示。

表 3 IWOA-BILSTM 超参数设置

Table 3 IWOA-BILSTM hyper-parameters settings

隐藏单元数	训练周期	L2Regularization	学习率 σ
(0,200)	(0,200)	(0.001,0.1)	(0.001,0.1)

以 DBO-VMD 对原始负荷分解后的 IMF1 分量为例, DBO-VMD-IWOA-BILSTM 的适应度曲线如图 10 所示, IWOA 对参数优化情况如图 11 所示。

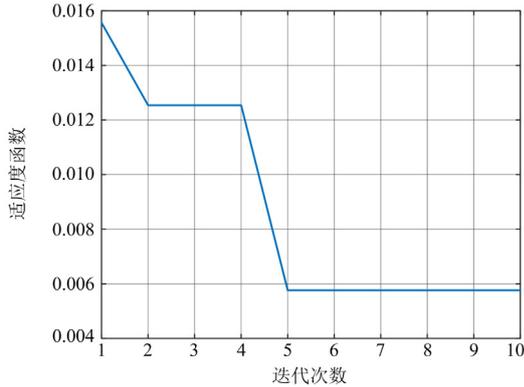


图 10 DBO-VMD-IWOA-BILSTM 适应度曲线

Fig. 10 DBO-VMD-IWOA-BILSTM fitness curve

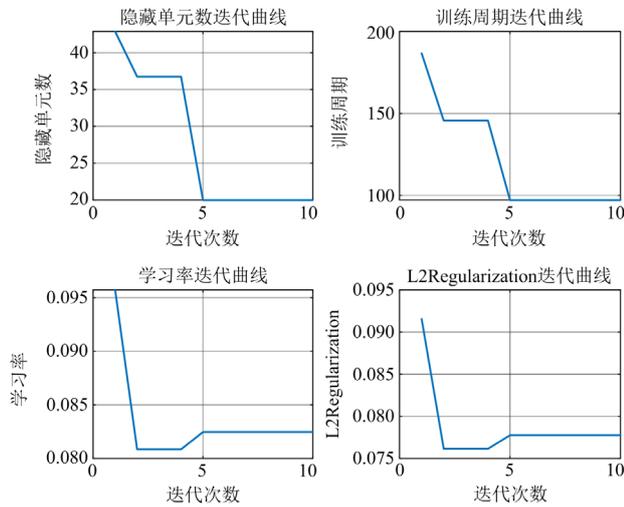


图 11 IWOA 优化超参数迭代结果

Fig. 11 Iterative results of IWOA optimization hyperparameters

最终优化得到的最优参数配置为: 隐藏单元数为 20; 最大训练周期为 97; 学习率为 0.082 467; L2Regularization 为 0.077 758。

为进一步验证本文模型的性能, 设置 3 组对比模型。

1) 对比模型一

最小二乘向量机(least squares vector machine, LSSVM)、LSTM、BILSTM、WOA-BILSTM、GWO-BILSTM、IWOA-BILSTM。

2) 对比模型二

DBO-VMD-WOA-BILSTM、DBO-VMD-GWO-BILSTM、DBO-VMD-IWOA-BILSTM。

3) 对比模型三

时域卷积网络(time-domain convolutional networks, TCN)、TRANSFORMER、GRU、CNN-LSTM、GA-BILSTM、DBO-VMD-DBO-BILSTM、IWOA-VMD-IWOA-BILSTM。

个别模型的重要参数如表 4 所示。

表 4 其他参数设置

Table 4 Other parameter settings

名称	参数
全局	滑动窗口大小为 16
	特征数目 $F = 4$
	Pop = 30
	Max_iteration = 30
训练参数	Optimizer = Adam
	Loss function = MSE
	learning rate(lr) = 0.01
	Min lr = 0.00001
CNN-LSTM	miniBatchSize = 32
	numFilters = 64
	filterSize = 3
TCN	numBlocks = 3
	skipConnections = true
Transformer	numHeads = 8
	numEncoderLayers = 3 numDecoderLayers = 3
GRU	numLayers = 2

各个模型均将预测的结果进行反标准化, 统一量纲。每个模型得到一周内 672 组预测数据, 为了更清晰地展示各模型之间的区别, 取一周内同一天的数据, 将 3 组对比模型的预测值以及真实负荷值分别绘制于图 12—图 14。同时, 为了更确切地表示各模型的性能, 运用评价指标计算各模型的相关误差值, 各模型预测评价指标具体数值如表 5 所示。

由表 5 可知: 在预测精度方面, IWOA-BILSTM 相对于 WOA-BILSTM 与 GWO-BILSTM 模型, E_{RRMSE} 分别降低了 42.12%与 41.84%, E_{MAE} 分别降低了 34.17%与 48.41%, E_{MAPE} 分别降低了 32.77%与 48.72%; 采用了 DBO-VMD 相结合的预测模型以后, DBO-VMD-IWOA-BILSTM 的预测模型相对于 DBO-VMD-WOA-BILSTM 以及 DBO-VMD-GWO-BILSTM 的预测模型, E_{RRMSE} 分别降低了 21.96%与

12.10%, E_{MAE} 分别降低了 21.29%与 10.40%, E_{MAPE} 分别降低了 16.46%与 8.33%; 对于其他对比模型, DBO-VMD-IWOA-BILSTM 模型相对于 IWOA-

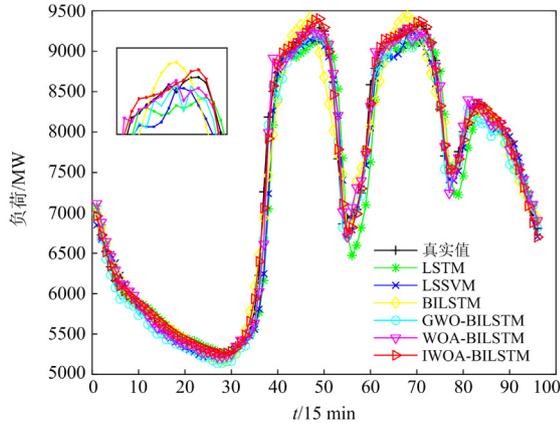


图 12 不同模型预测结果 1

Fig. 12 Different models' prediction result 1

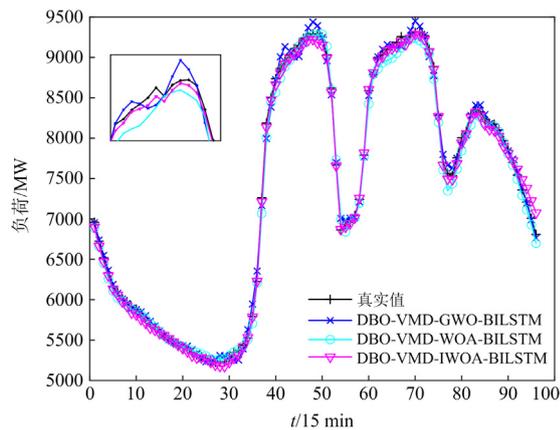


图 13 不同模型预测结果 2

Fig. 13 Different models' prediction result 2

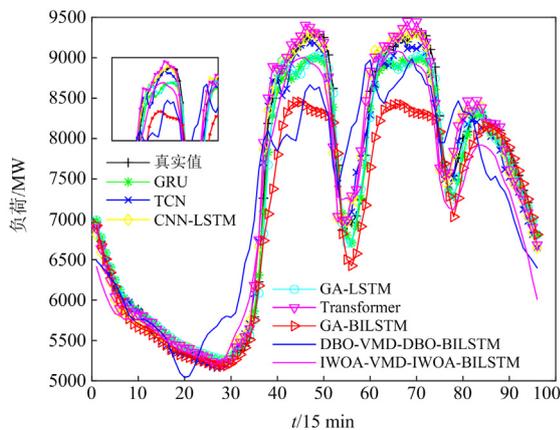


图 14 不同模型预测结果 3

Fig. 14 Different models' prediction result 3

表 5 各模型预测结果对比

Table 5 Comparison of prediction results of various models

模型	E_{RRMSE}/MW	E_{MAE}/MW	$E_{MAPE}/\%$
DBO-VMD-DBO-BILSTM	0.0839	515.63	7.02
GA-BILSTM	0.0680	358.10	4.32
IWOA-VMD-IWOA-BILSTM	0.0518	315.29	4.21
LSTM	0.0408	181.25	2.38
CNN-LSTM	0.0313	155.65	2.11
Transformer	0.0313	148.63	1.96
BILSTM	0.0309	154.25	1.98
LSSVM	0.0288	132.15	1.75
TCN	0.0267	155.38	2.10
GRU	0.0230	130.32	1.60
GA-LSTM	0.0224	116.69	1.46
GWO-BILSTM	0.0190	113.25	1.56
WOA-BILSTM	0.0191	88.76	1.19
IWOA-BILSTM	0.0111	58.43	0.80
DBO-VMD-WOA-BILSTM	0.0109	61.10	0.79
DBO-VMD-GWO-BILSTM	0.0097	53.67	0.72
DBO-VMD-IWOA-BILSTM	0.0084	48.09	0.66

BILSTM、GA-BILSTM 和 GA-LSTM 模型, E_{RRMSE} 分别降低了 23.32%、87.51%、62.09%, E_{MAE} 分别降低了 23.32%、87.51%、62.09%, E_{MAPE} 分别降低了 17.50%、84.72%、54.79%; DBO-VMD-IWOA-BILSTM 模型相对于 GRU、TCN、Transformer、CNN-LSTM 模型, E_{RRMSE} 分别降低了 63.12%、68.25%、72.85%、72.91%, E_{MAE} 分别降低了 63.10%、69.05%、67.64%、59.91%, E_{MAPE} 分别降低了 58.75%、68.57%、66.33%、68.72%; DBO-VMD-IWOA-BILSTM 模型相对于 DBO-VMD-DBO-BILSTM、IWOA-VMD-IWOA-BILSTM 模型, E_{RRMSE} 分别降低了 89.88%、83.63%, E_{MAE} 分别降低了 90.67%、80.21%, E_{MAPE} 分别降低了 90.60%、84.32%。

可见 DBO-VMD-IWOA-BILSTM 预测模型结果更加准确, 对特征的处理能进一步提升预测的精准度。各预测结果表明, DBO-VMD-IWOA-BILSTM 模型相对于其他几个对比模型, 具有更高的预测精度, 预测效果更好。

5 结语

针对不规律的、波动性大的复杂原始负荷数据导致预测难度大、难以准确进行负荷预测等问题, 本文提出基于 DBO-VMD 和 IWOA-BILSTM 相组合的短期电力负荷预测模型。首先用 DBO-VMD 算

法将复杂、非平稳的原始数据分解成各异的模态分量,然后使用 IWOA 对 BILSTM 模型进行优化来提高模型预测精度。以某地区真实数据为原始负荷数据,将本文提出的模型与其他预测模型进行对比实验,得出以下结论。

1) DBO 对 VMD 的分解参数进行优化,可以有效降低分解参数的随机性,增强分解效果。原始负荷数据经过 DBO-VMD、达到了对原始负荷数据去噪的效果,其不规则性、波动性大大降低。

2) 通过非线性收敛因子、自适应权重策略与随机差分法变异策略对传统的鲸鱼算法进行改进,能够有效避免陷入局部最优值,实现更佳寻优效果。

3) 对于相同数据集,与基于其他模型的负荷预测方法相比,本文提出的基于 DBO-VMD 和 IWOA-BILSTM 的短期电力负荷预测模型具有更高的预测精度,验证了本文模型的优越性,为电力系统的后续优化调度奠定了基础。

参考文献

- [1] 刘倩, 胡强, 杨凌帆, 等. 基于时间序列的深度学习光伏发电模型研究[J]. 电力系统保护与控制, 2021, 49(19): 87-98.
LIU Qian, HU Qiang, YANG Lingfan, et al. Deep learning photovoltaic power generation model based on time series[J]. Power System Protection and Control, 2021, 49(19): 87-98.
- [2] LI B, LU M, ZHANG Y, et al. A weekend load forecasting model based on semi-parametric regression analysis considering weather and load interaction[J]. Energies, 2019, 12(20): 3820.
- [3] YUAN S. Analysis of electric load data based on time series[J]. Advances in Applied Mathematics, 2016, 5(2): 214-224.
- [4] 黄冬梅, 陈欢, 王宁, 等. 基于自适应注意力网络的短期用户负荷预测[J]. 电力系统保护与控制, 2023, 51(20): 140-149.
HUANG Dongmei, CHEN Huan, WANG Ning, et al. Short-term user load prediction based on an adaptive graph attention network[J]. Power System Protection and Control, 2023, 51(20): 140-149.
- [5] GUO Hongye, CHEN Qixin, ZHENG Kedi, et al. Forecast aggregated supply curves in power markets based on LSTM model[J]. IEEE Transactions on Power Systems, 2021, 36(6): 5767-5779.
- [6] 董彦军, 王晓甜, 马红明, 等. 基于随机森林与长短期记忆网络的电力负荷预测方法[J]. 全球能源互联网, 2022, 5(2): 147-156.
DONG Yanjun, WANG Xiaotian, MA Hongming, et al. Power load forecasting method based on random forest and long short-term memory[J]. Journal of Global Energy Interconnection, 2022, 5(2): 147-156.
- [7] 杨书强, 王涛, 檀晓林, 等. 基于长短期记忆的图像化短期电力负荷预测方法[J]. 全球能源互联网, 2023, 6(3): 282-288.
YANG Shuqiang, WANG Tao, TAN Xiaolin, et al. Image based short-term power load forecasting method using long short-term memory[J]. Journal of Global Energy Interconnection, 2023, 6(3): 282-288.
- [8] CIECHULSKI T, OSOWSKI S. High precision LSTM model for short-time load forecasting in power systems[J]. Energies, 2021, 14(11).
- [9] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A. A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BILSTM[EB/OL]. [2021-07-23]. <https://arxiv.org/pdf/1911.09512.pdf>.
- [10] ZHEN Hao, NIU Dongxiao, WANG Keke, et al. Photovoltaic power forecasting based on GA improved Bi-LSTM in microgrid without meteorological information[J]. Energy, 2021, 231.
- [11] LIU Zhaosu, YANG Jianfeng. Research on short-term load forecasting based on GWO-BILSTM[J]. Journal of Physics: Conference Series, 2022, 2290(1).
- [12] LI B, PAN H. Global temperature prediction by BILSTM model based on whale optimization algorithm and attention mechanism[C] // 2023 3rd International Conference on Neural Networks, Information and Communication Engineering (NNICE), 2023, Guangzhou, China: 651-657.
- [13] 刘新宇, 蒲欣雨, 李继方, 等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. 电力系统保护与控制, 2023, 51(21): 158-165.
LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. Power System Protection and Control, 2023, 51(21): 158-165.
- [14] 寿绍安, 罗海荣, 王晓康, 等. 基于 VMD-ISODATA-DBN 的配电台区短期负荷预测方法[J]. 智慧电力, 2023, 51(11): 53-60.
SHOU Shao'an, LUO Hairong, WANG Xiaokang, et al. Forecasting method of short-term load in distribution station area based on VMD-ISODATA-DBN[J]. Smart Power, 2023, 51(11): 53-60.
- [15] 汤义勤, 邹宏亮, 蒋旭, 等. 基于 VMD 和贝叶斯优化 LSTM 的母线负荷预测方法[J]. 电网与清洁能源, 2023, 39(2): 46-52, 59.
TANG Yiqin, ZOU Hongliang, JIANG Xu, et al. A bus

- load forecasting method based on VMD and bayesian optimization LSTM[J]. Power System and Clean Energy, 2023, 39(2): 46-52, 59.
- [16] 王粟, 江鑫, 曾亮, 等. 基于 VMD-DESN-MSGP 模型的超短期光伏功率预测[J]. 电网技术, 2020, 44(3): 917-926.
WANG Su, JIANG Xin, ZENG Liang, et al. Ultra-short-term photovoltaic power prediction based on VMD-DESN-MSGP model[J]. Power System Technology, 2020, 44(3): 917-926.
- [17] 孙祥晟, 陈芳芳, 吴孟礼, 等. 基于 EMD 分解的 AR 模型光伏发电预测方法探讨[J]. 电工技术, 2019(11): 8-10, 14.
SUN Xiangsheng, CHEN Fangfang, WU Mengli, et al. Discussion on prediction method of photovoltaic power generation of AR model based on EMD decomposition[J]. Journal of Electrical Engineering, 2019(11): 8-10, 14.
- [18] 陈陈, 李晓明, 杨玲君, 等. 变分模态分解在电力系统谐波检测中的应用[J]. 电力系统保护与控制, 2018, 46(14): 63-70.
CHEN Chen, LI Xiaoming, YANG Lingjun, et al. Application of variational mode decomposition in power system harmonic detection[J]. Power System Protection and Control, 2018, 46(14): 63-70.
- [19] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2022, 50(21): 138-148.
SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. Power System Protection and Control, 2022, 50(21): 138-148.
- [20] XUE Jiankai, BO Shen. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [21] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [22] 季玉琦, 严亚帮, 和萍, 等. 基于 K-Medoids 聚类与栅格法提取负荷曲线特征的 CNN-LSTM 短期负荷预测[J]. 电力系统保护与控制, 2023, 51(18): 81-93.
JI Yuqi, YAN Yabang, HE Ping, et al. CNN-LSTM short-term load forecasting based on the K-Medoids clustering and grid method to extract load curve features[J]. Power System Protection and Control, 2023, 51(18): 81-93.
- [23] ZHENG R, YU J, WANG Y, et al. A short-term residential load forecast model based on BILSTM-MDN[C] // 2022 IEEE International Conference on Networking, Sensing and Control (ICNSC), December 15-18, 2022, Shanghai, China: 1-6.
- [24] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [25] DING H, WU Z, ZHAO L. Whale optimization algorithm based on nonlinear convergence factor and chaotic inertial weight[J]. Concurrency and Computation: Practice and Experience, 2020, 32(24): 5949.
- [26] 郭振洲, 王平, 马云峰, 等. 基于自适应权重和柯西变异的鲸鱼优化算法[J]. 微电子学与计算机, 2017, 34(9): 20-25.
GUO Zhenzhou, WANG Ping, MA Yunfeng, et al. Whale optimization algorithm based on adaptive weight and cauchy mutation[J]. Microelectronics & Computer, 2017, 34(9): 20-25.
- [27] 王涛, CHELLALI R. 非线性权重和收敛因子的鲸鱼算法[J]. 微电子学与计算机, 2019, 36(1): 11-15.
WANG Tao, CHELLALI R. Whale optimization algorithm with nonlinear weight and convergence factor[J]. Microelectronics & Computer, 2019, 36(1): 11-15.
- [28] 曹文梁. 随机差分变异粒子群混合优化算法[J]. 电子测量与仪器学报, 2017, 31(6): 928-933.
CAO Wenliang. Hybrid algorithm based on particle swarm optimization with stochastic differential mutation[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(6): 928-933.
- [29] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059-162080.
- [30] 武泽权, 牟永敏. 一种改进的鲸鱼优化算法[J]. 计算机技术与发展, 2023, 33(2): 173-180.
WU Zequan, MOU Yongmin. An improved whale optimization algorithm[J]. Computer Technology and Development, 2023, 33(2): 173-180.

收稿日期: 2023-11-01; 修回日期: 2024-01-05

作者简介:

刘杰(1996—), 男, 硕士研究生, 研究方向为综合能源系统优化与控制; E-mail: 1793126529@qq.com

从兰美(1968—), 女, 通信作者, 博士, 教授, 硕士生导师, 主要研究方向为电力系统运行与控制, 综合能源系统优化与控制, 智能控制等。E-mail: lysyclm@126.com

(编辑 姜新丽)