

基于MSWOA改进Attention-BiGRU模型的 电力负荷预测

王童

(浙江理工大学计算机科学与技术学院, 浙江 杭州 310018)

摘要: 为了提高短期电力负荷的预测精度,提出一种基于混合策略改进鲸鱼优化算法(MSWOA)的Attention-BiGRU短期电力预测模型。该模型首先利用双向长短期记忆网络(BiGRU)对电力数据的时序特征信息进行双向提取,并引入Attention机制,根据提取信息的特点,对隐藏状态的信息赋予不同比重,以增大重要信息的影响。针对模型的参数选取问题,通过MSWOA算法自动选取神经网络的模型参数,并优化网络模型参数使预测效果最优。通过对电力负荷数据进行训练与预测,与BiGRU、Attention-BiGRU、鲸鱼优化算法(WOA)改进的Attention-BiGRU等模型的预测结果进行对比。实验结果表明,该优化模型的预测精度达到98.829%,相较于传统的WOA,改进后的WOA对Attention-BiGRU网络模型的优化有更好的效果,且相较于人工选择参数的神经网络模型具有更高的准确性和稳定性。

关键词: 电力预测;BiGRU;注意力机制;改进鲸鱼优化算法

DOI: 10.11907/rjdk.222277

中图分类号: TP183

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2023)010-0084-06



Power Load Forecasting Based on MSWOA Improved Attention-BiGRU Model

WANG Tong

(School of Computer Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: In order to improve the accuracy of short-term power load forecasting, this paper proposes a mixed strategy based improved whale optimization algorithm (MSWOA) improved Attention-BiGRU short-term electric power forecasting model. The model first uses bidirectional gating recurrent unit (BiGRU) to extract the information of temporal characteristics of power data in both directions, and introduces Attention mechanism to give different weights to the information of hidden states according to the characteristics of extracted information to increase the influence of important information. To deal with the parameter selection problem of the model, the parameters of the neural network model are automatically selected by the MSWOA algorithm, and the parameters of the network model are optimized to make the optimal prediction effect. And by training and prediction of electric load data, the prediction results are compared with those of BiGRU, Attention-BiGRU, and the whale optimization algorithm (WOA) improved Attention-BiGRU models. The test results show that the prediction accuracy of the optimization model proposed in this paper reaches 98.829%, which has better results compared with the traditional WOA model for the improved Attention-BiGRU network model, and has higher accuracy and stability compared with the neural network model with manually selected parameters.

Key Words: power prediction; bidirectional gating recurrent unit; Attention mechanism; improved whale optimization algorithm

0 引言

近年来,随着能耗双控政策的升级,多地发布了限电令,许多大型能耗企业被迫限电停产,购电价格也再次提高。如何节省成本、合理安排用电成为许多钢铁企业亟需解决的问题。在此情况下,钢铁行业只有对消耗的电力状

况进行精准预测,才能避免电力资源浪费,并制定有效的电力管理策略,以保证在能耗双控的政策下,企业能够合理分配电力资源,保证正常生产^[1]。

针对电力负荷预测的研究,主要是基于其时序性的特点^[2],根据时间序列叠加来预测未来负荷的数据^[3]。传统的电力预测方法主要以基于统计学方法的预测为主^[4],包括自回归分析、指数平滑模型等方法。传统电力预测方法

收稿日期:2022-10-28

基金项目:激光与物质相互作用国家重点实验室开发基础研究课题(SKLLIM2113)

作者简介:王童(1996-),男,浙江理工大学计算机科学与技术学院硕士研究生,研究方向为计算机应用技术。

的模型较为简单,受人工影响因素较大^[5],无法针对电力负荷数据的特点进行拟合,因此准确性不高。现代的电力预测方法主要以基于机器学习和神经网络的预测为主^[6],包括随机森林、极限学习机(Extreme Learning Machine, ELM)和循环神经网络(Recurrent Neural Network, RNN)等^[7-9]。龚飘怡等^[10]提出一种基于 Attention-BiLSTM-LSTM 的预测方法,将 Attention 注意力机制与 BiLSTM-LSTM 混合预测模型叠加,结合 BiLSTM 与 LSTM 的优势,验证了预测模型在电力预测方面的有效性;张子阳等^[11]等利用灰色关联和麻雀搜索算法对最小二乘支持向量机(Least Squares Support Vector Machines, LSSVM)进行模型参数优化,提高了 LSSVM 模型的准确性和稳定性;张翼飞等^[12]通过鲸鱼优化算法(Whale Optimization Algorithm, WOA)改进 BiLSTM 神经网络参数,通过对风场发电数据进行训练,验证了模型性能,证实了鲸鱼优化算法对于神经网络参数优化的可行性。

在上述的负荷预测算法中,模型参数选取往往是根据经验手动设置的,对于参数的选择通常没有进行深入研究,而神经网络参数对模型性能有很大影响。因此,本文提出一种基于混合策略改进鲸鱼优化算法(Mix Strategy Based Improved Whale Optimization Algorithm, MSWOA)的 Attention-BiGRU 短期电力预测模型,利用 MSWOA 自动选取神经网络模型参数。BiGRU 不仅解决了梯度消失和过拟合问题,而且融合了电力负荷数据过去和未来的时序因素^[13],结合 Attention 注意力机制,考虑不同时间序列的不同影响,分别对时间序列每一个特征赋予不同比重^[14-15],再通过 MSWOA 对神经网络模型参数进行优化,预测未来的电力数据。将优化后的模型和 BiGRU、Attention-BiGRU、WOA 模型进行比较,结果表明,MSWOA 优化后模型的准确率和稳定性都有一定提高。

1 电力预测模型

1.1 BiGRU 模型

GRU 是针对 LSTM 的一种变体,其通过引进门机制,将 LSTM 中的输出门和遗忘门合并,减少了 LSTM 的训练参数,并加快了训练时间。其不仅有效解决了 RNN 的梯度消失和梯度爆炸问题,而且在一定程度上缓解了过拟合^[16]。GRU 内部由更新门和重置门共同作用,其中更新门与历史状态的输出信息有关,重置门代表当前输入对历史状态的遗忘程度。GRU 具体内部结构如图 1 所示。

由图 1 可得出 GRU 的公式如下:

$$r_t = \sigma(W_{xr}x_t + b_{xr} + W_{hr}h_{t-1} + b_{hr}) \quad (1)$$

$$z_t = \sigma(W_{xz}x_t + b_{xz} + W_{hz}h_{t-1} + b_{hz}) \quad (2)$$

$$n_t = \tanh(r_t \circ (W_{hn}h_{t-1} + b_{hn}) + W_{xn}x_t + b_{xn}) \quad (3)$$

$$h_t = z_t \circ h_{t-1} + (1 - z_t) \circ n_t \quad (4)$$

其中, x_t 为当前状态的输入, h_{t-1} 为上一时间步的输

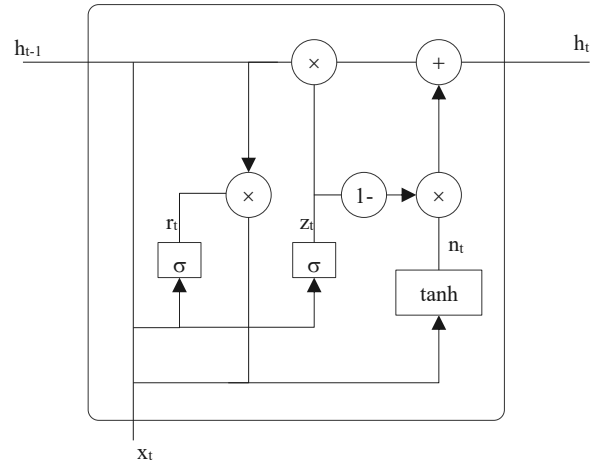


Fig. 1 GRU unit model

图 1 GRU 单元模型

出, h_t 为当前时刻的输出, r_t, z_t 分别代表重置门和更新门。 $W_{xr}, W_{hr}, W_{xz}, W_{hz}, W_{hn}$ 和 W_{xn} 为权重系数矩阵, $b_{xr}, b_{hr}, b_{xz}, b_{hz}, b_{hn}$ 和 b_{xn} 为偏置项矩阵。 σ 代表 sigmoid 函数, \tanh 代表双曲正切函数, \circ 代表两个矩阵的点积。

由于 GRU 只是沿着时间序列向前传播,只考虑了历史数据的影响,而忽略了未来时刻的数据信息。因此,本文选用双向长短期记忆网络(Bidirectional Gating Recurrent Unit, BiGRU)作为神经网络模型, BiGRU 由沿着时间序列前向传播的 GRU 和反向传播的 GRU 叠加而成,可以对电力负荷的双向时序特征进行有效提取。BiGRU 传播模型如图 2 所示。通过 GRU 的正向传播和反向传播,最终决定了 h_t 的输出结果。

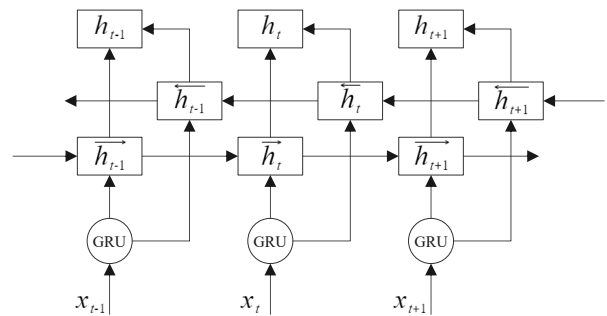


Fig. 2 BiGRU propagation model

图 2 BiGRU 传播模型

其中, x_t 为 t 时刻的输入, \vec{h}_t 为 GRU 的正向传播过程, \overleftarrow{h}_t 为 GRU 的反向传播过程。

1.2 Attention 机制

Attention 机制是对人脑视觉注意力的仿生,可以通过注意力机制锁定重要信息,通过考虑输入特征对输出结果的影响来赋予输入特征以不同权重。由此可以通过权重大小提高某些重要特征输出占比,同时忽略不重要的特征,以更好地预测输出结果。Attention 机制原理图如图 3 所示。




Fig. 3 Schematic diagram of Attention mechanism

图3 Attention 机制原理

其中, $y = \sum_{i=1}^l \alpha_i h_i$ 为 Attention 机制的输出, h_i 对应图 2 中 BiGRU 网络单元的输出, α_i 对应 Attention 机制分配给每一项的权重。

1.3 鲸鱼优化算法

鲸鱼优化算法是一种模拟鲸鱼狩猎过程的仿生优化算法。鲸鱼优化算法包含搜索猎物、包围猎物和螺旋式更新 3 个过程。在鲸鱼狩猎过程中, 鲸鱼会根据当前所在位置选择不同的狩猎方式来更新下一次的位置。

1.3.1 搜索猎物

当进入搜索猎物阶段, 由于猎物位置不确定, 鲸鱼个体会随机寻找猎物, 根据随机个体的位置进行更新, 搜索猎物所在位置。当 $|a| > 1$ 时, 鲸鱼根据公式(5)进行位置更新, 由鲸鱼第 t 次的位置坐标计算更新第 $t + 1$ 次的位置坐标。

$$\begin{cases} X(t+1) = X_r(t) - A \cdot D_r \\ D_r = |cX_r(t) - X(t)| \\ A = 2ar - a \\ c = 2r \end{cases} \quad (5)$$

其中, $X_r(t)$ 为随机鲸鱼所在位置, $X(t)$ 为第 t 次更新后鲸鱼所在位置, r 为 0~1 之间的随机数, $a = 2 - 2\frac{t}{T}$, T 为迭代更新的总次数。

1.3.2 包围猎物

当 $|a| \leq 1$ 时, 鲸鱼由搜索猎物阶段进入包围阶段, 假设鲸鱼适应度最优的位置就是猎物所在位置, 此时会根据最优个体的位置对鲸鱼群体进行更新, 按照公式(6)更新鲸鱼个体的位置。

$$\begin{cases} X(t+1) = X^*(t) - A \cdot D_1 \\ D_1 = |cX^*(t) - X(t)| \end{cases} \quad (6)$$

其中, $X^*(t)$ 为鲸鱼适应度最优的位置。

1.3.3 螺旋式更新

螺旋式更新是鲸鱼独有的狩猎方式, 通过螺旋式游动更新位置, 边包围边将猎物逼向海面对其进行围捕, 更新公式如下:

$$\begin{cases} X(t+1) = D_2 e^{bl} \cos(2\pi l) + X^*(t) \\ D_2 = |X^*(t) - X(t)| \end{cases} \quad (7)$$

其中, b 为常数, l 是 $[-1, 1]$ 之间的随机数。

鲸鱼在螺旋式更新的同时还需要对猎物进行围捕, 为了模拟两种围捕方式, 需要设置随机概率 p 实现模拟过程。当 $p \geq 0.5$ 时, 鲸鱼进行螺旋式更新; 当 $p < 0.5$ 时, 鲸鱼进行包围式更新。更新公式如下:

$$\begin{cases} X(t+1) = D_2 e^{bl} \cos(2\pi l) + X^*(t), p \geq 0.5 \\ X(t+1) = X^*(t) - A \cdot D_1, p < 0.5 \end{cases} \quad (8)$$

1.3.4 混合策略改进的鲸鱼优化算法

针对 WOA 算法更新过程中出现的收敛速度缓慢和容易陷入局部最优等问题, 混合策略改进的鲸鱼优化算法在 WOA 基础上进行了优化改进。通过引入非线性收敛因子和自适应权值, 分别对前后期的 WOA 算法进行分段式处理, 有效加快了搜索速度, 引导算法跳出局部最优解, 提高了算法的稳定性^[17]。收敛因子 a 的计算公式如下:

$$a = \begin{cases} 1 + \cos \frac{\pi t}{T}, t \leq 0.5T \\ \cos \frac{\pi(t - 0.5T)}{T}, t > 0.5T \end{cases} \quad (9)$$

更新后的 MSWOA 算法如下:

$$\begin{cases} X(t+1) = D_2 e^{bl} \cos(2\pi l) + (1 - \omega)X^*(t), p \geq 0.5 \\ X(t+1) = \omega X_r(t) - A \cdot D_r, p < 0.5, |a| > 1 \\ X(t+1) = \omega X^*(t) - A \cdot D_1, p < 0.5, |a| \leq 1 \end{cases} \quad (10)$$

其中, $\omega = \frac{2}{\pi} \tan \frac{t}{T}$ 代表自适应权值。

1.4 基于 MSWOA 的 Attention-BiGRU 模型构建

在循环神经网络的训练中, 隐藏层节点数、迭代次数和学习率的选取对神经网络模型的性能影响非常大。在传统的神经网络训练中, 参数选取是根据经验人工进行调节的, 受主观因素影响很大, 网络性能受到影响将无法得出最优模型。因此, 本文提出利用 MSWOA 优化算法对网络参数进行选择, 将神经网络参数作为鲸鱼的位置, 选择均方误差作为适应度函数。

$$f = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (11)$$

其中, m 为训练样本数, y_i 为实际值, \hat{y}_i 为预测值。

通过混合策略改进的鲸鱼优化算法对参数位置进行更新, 选取出适应度最好的参数作为神经网络的模型参数。优化后的网络参数不仅解决了神经网络容易陷入局部最优解的问题, 而且提高了 Attention-BiGRU 网络模型的精度。算法实现过程如图 4 所示。

具体实现步骤如下:

(1) 搭建神经网络模型, 设置鲸鱼的种群数量和优化算法迭代次数。选取隐藏节点数、迭代次数和学习率作为鲸鱼的位置坐标, 利用 Sobol 随机序列对鲸鱼群体位置进行初始化。

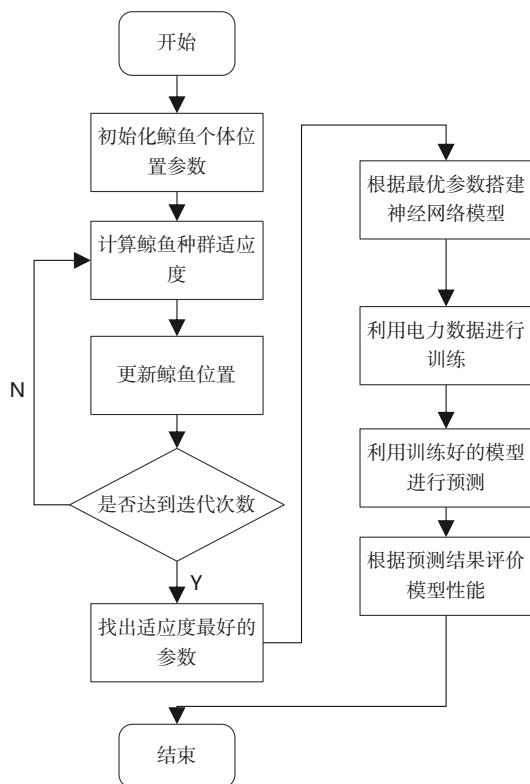


Fig. 4 MSWOA-based Attention-BiGRU training process

图 4 基于 MSWOA 的 Attention-BiGRU 训练过程

(2) 利用公式(11)计算出鲸鱼个体的适应度,随机初始化参数 r 和 p , 根据 r 计算 A 的值, 根据 p 和 A 判断鲸鱼的狩猎方式, 并根据公式(10)更新鲸鱼群体的位置。

(3) 重复步骤(2)直到达到迭代次数, 计算迭代之后的鲸鱼个体适应度, 输出适应度最好的个体坐标作为神经网络参数。

(4) 利用得到的神经网络参数搭建 Attention-BiGRU 神经网络模型, 结合电力负荷数据进行训练验证, 并对日负荷数据进行预测, 根据预测结果判断神经网络的性能。

2 实验结果与分析

2.1 数据集及评价指标

为了验证算法性能, 本文选用 2016 年电工数学建模竞赛的电力负荷数据集进行训练^[18]。将 2012 年 1 月 1 日—2015 年 1 月 9 日的电力负荷数据按照 8:2 的比例划分, 分为训练集和验证集, 对网络模型进行训练, 并对 2015 年 1 月 10 日的日数据进行预测。本文选择均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 作为评价指标。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (12)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (13)$$

其中, y_i 为真实值, \hat{y}_i 为预测值, m 为预测日负荷点数。

2.2 数据预处理

2.2.1 异常数据处理

考虑到记录电力负荷时, 若由于突发状况导致电力负荷数据异常, 会出现突然的负荷数据过大或过小的情况, 从而影响神经网络训练性能, 导致预测结果不准确, 因此需要对电力负荷数据进行修正。根据公式(14)判断是否为异常数据^[19], 如果满足公式(14), 说明该点数据异常, 将相邻两点的电力负荷数据均值作为该点的修正值。

$$\begin{cases} y_i \geq 1.1y_{i-1} \text{ 或 } y(i) \leq 0.9y_{i-1}, i \neq 1, m \\ y_i \geq 1.1y_{i+1} \text{ 或 } y(i) \leq 0.9y_{i+1} \end{cases} \quad (14)$$

其中, y_i 为第 i 个时刻的电力负荷数据, m 为预测日负荷点数。

2.2.2 数据归一化处理

本文采用每日的整点电力负荷数据进行预测, 选取前 7 天的数据, 并对后一日的数据进行预测。因此, 输入数据维度为 24, 时间序列长度为 7, 输出数据维度为 24。为了便于训练, 加快网络收敛速度, 需要对数据进行归一化处理, 利用公式(15)对电力负荷数据进行归一化, 将数据转换到 $[0, 1]$ 范围内。

$$x = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

其中, x 是日负荷数据, x_{\min} 是日负荷数据最小值, x_{\max} 是日负荷数据最大值。

2.3 实验结果分析

本文将 MSWOA 优化的 Attention-BiGRU 网络模型与 BiGRU、Attention-BiGRU 和 WOA 优化的 Attention-BiGRU 模型进行比较, 验证 MSWOA 算法对网络性能提升的有效性。其中, BiGRU 和 Attention-BiGRU 的输入节点数为 24, 隐藏层节点数为 32, 输出节点数为 24, 训练迭代次数为 250, 学习率为 0.01。WOA 和 MSWOA 初始化鲸鱼种群数量为 10, 最大迭代次数为 30, 鲸鱼位置维度为 3, 并通过优化算法自动选取隐藏层节点数、学习率和迭代次数来搭建神经网络进行训练。

采用 WOA 算法和 MSWOA 算法对神经网络参数进行优化, 得出神经网络的最佳参数如表 1 所示。

Table 1 Network parameters obtained after algorithm optimization
表 1 算法优化后得到的网络参数

算法	学习率	隐藏层数	迭代次数
WOA	0.007 804 139 64	100	173
MSWOA	0.005 705 415 20	49	112

训练 4 种神经网络模型, 并对某一天的神经网络进行预测, 预测结果如图 5 所示。计算预测日的 RMSE 和 MAPE 如表 2 所示。

由表 2 可知, MSWOA 的 RMSE 和 MAPE 都低于其他模型。MSWOA 的 MAPE 为 1.171%, 分别比 BiGRU、Attention-BiGRU、WOA 低了 1.184、0.923、0.479 个百分点; RMSE 为 108.834 MW, 分别比 BiGRU、Attention-BiGRU、WOA 低了 115.368、88.760、72.341 MW。

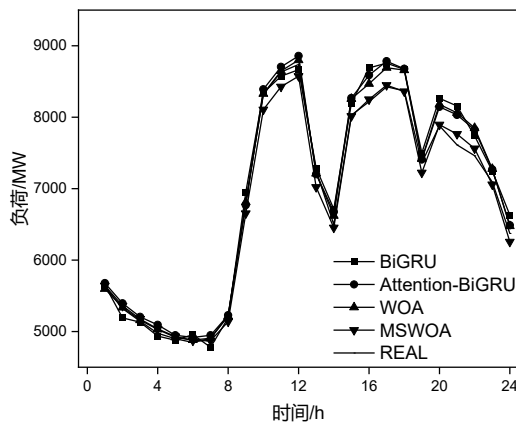


Fig. 5 Prediction results of different models for one day
图5 不同模型一天的预测结果

Table 2 Comparison of the error of different models for one day
表2 不同模型一天的误差比较

模型	RMSE/MW	MAPE/%
BiGRU	224.202	2.355
Attention-BiGRU	197.594	2.094
WOA	181.175	1.650
MSWOA	108.834	1.171

为了更好地判断神经网络模型的性能,对电力数据进行连续7天的电力预测,预测结果如图6所示。计算预测日的RMSE和MAPE如表3所示。

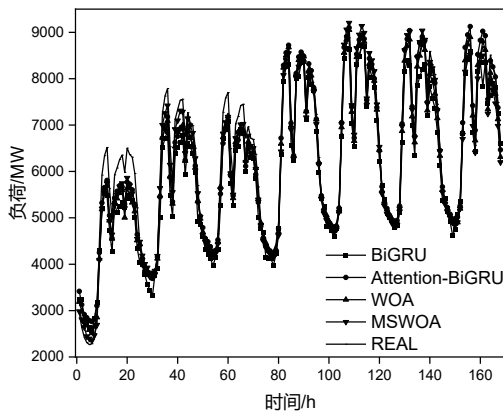


Fig. 6 Prediction results of different models for seven days
图6 不同模型7天的预测结果

Table 3 Comparison of the error of different models for seven days
表3 不同模型7天的误差比较

模型	RMSE/MW	MAPE/%
BiGRU	482.122	6.248
Attention-BiGRU	330.996	4.437
WOA	340.764	4.171
MSWOA	300.734	3.611

由表3可知,MSWOA的RMSE和MAPE都低于其他模型。MSWOA的MAPE为3.611%,分别比BiGRU、Attention-BiGRU、WOA低了2.637、0.826、0.560个百分点;RMSE为300.734 MW,分别比BiGRU、Attention-BiGRU、WOA低了181.388、30.262、40.030 MW。根据预测结果可

知,由MSWOA算法优化得到的网络模型,相较于其他网络模型的性能更好,证明了MSWOA算法能够有效提升神经网络的预测性能。

3 结语

本文针对短期电力负荷预测提出一种基于MSWOA的Attention-BiGRU网络模型,利用BiGRU的时序性预测特性,引入Attention注意力机制提高神经网络的性能,并通过混合策略改进的鲸鱼优化算法自动选取隐藏层数、训练次数和学习率。结合电力负荷数据进行验证,实验结果证明,MSWOA可有效提高神经网络的预测精度。同时与WOA相比,MSWOA在神经网络参数寻优过程中更具有优势,改善了WOA收敛速度慢的缺点。由于本文只是针对单一电力负荷数据参数进行验证,未来可考虑加入天气等其它因素进一步验证模型性能。

参考文献:

- [1] SAMEH M, LARBI C A, BRUNO M, et al. Predicting energy consumption using LSTM, multi-Layer GRU and drop-GRU neural networks [J]. Sensors, 2022, 22(11):4062.
- [2] CHENG Z W. Research on the detection and prediction of power consumption anomalies based on machine learning [D]. Chongqing: Chongqing University of Posts and Telecommunications, 2020.
程占伟. 基于机器学习的电力能耗异常检测与预测研究[D]. 重庆:重庆邮电大学,2020.
- [3] LIU H Q, GAO F, WANG Y L, et al. Short-term electric load forecasting based on Dropout-ILSTM network [J]. Electricity Measurement and Instrumentation, 2021, 58(5): 105-111.
刘皓琪, 高飞, 王耀力, 等. 基于Dropout-ILSTM网络的短期电力负荷预测[J]. 电测与仪表, 2021, 58(5): 105-111.
- [4] WU M F, ZHANG G J, JIN C H. A time series prediction model based on multimodal information fusion [J]. Computer Applications, 2022, 42(8): 2326-2332.
吴明晖, 张广洁, 金苍宏. 基于多模态信息融合的时间序列预测模型[J]. 计算机应用, 2022, 42(8): 2326-2332.
- [5] SU W J, LIU M J. Optimized Attention-Bi LSTM model based on whale algorithm for short-term ship traffic prediction [J]. Journal of Wuhan University of Technology, 2022, 44(5):34-39.
苏伟杰, 刘明俊. 基于鲸鱼算法优化Attention-Bi LSTM模型的短期船舶流量预测[J]. 武汉理工大学学报, 2022, 44(5): 34-39.
- [6] LI W, QUAN C X, WANG X Y, et al. Short-term power load forecasting based on a combination of VMD and ELM [J]. Polish Journal of Environmental Studies, 27(5):2143-2154.
- [7] HAN L Y. Research on the application of machine learning with fused data preprocessing in power forecasting [D]. Beijing: North China Electric Power University (Beijing), 2016.
韩立辉. 融合数据预处理的机器学习在电力预测中的应用研究[D]. 北京:华北电力大学(北京), 2016.
- [8] WANG Y R, WANG S Y. GRU-based neural network for electric load

- forecasting[J]. Electrotechnology, 2022(10): 123-125, 129.
王悦如, 王盛宇. 基于GRU神经网络的电力负荷预测[J]. 电工技术, 2022(10): 123-125, 129.
- [9] LI J, PENG Y H, CHENG Z Y, et al. Prediction and analysis on short-term load of power system based on LSTM[J]. Meteorological and Environmental Research, 2022, 13(4): 116-117, 124.
- [10] GONG P Y, LUO Y F, FANG Z M, et al. Short-term electric load forecasting method based on Attention-BiLSTM-LSTM neural network[J]. Computer Applications, 2021, 41(S1): 81-86.
龚飘怡, 罗云峰, 方哲梅, 等. 基于 Attention-BiLSTM-LSTM 神经网络的短期电力负荷预测方法[J]. 计算机应用, 2021, 41(S1): 81-86.
- [11] ZHANG Z Y, WANG K K. Electricity load forecasting based on gray correlation and sparrow search algorithm[J]. Journal of Liaoning University of Engineering and Technology (Natural Science Edition), 2022, 41(3): 283-288.
张子阳, 王珂珂. 基于灰色关联和麻雀搜索算法的电力负荷预测[J]. 辽宁工程技术大学学报(自然科学版), 2022, 41(3): 283-288.
- [12] ZHANG Y F, PI Z Y, ZHU R Q, et al. Wind power prediction based on WOA-BiLSTM neural network[J]. Electrical Technology, 2022(10): 28-31.
张翼飞, 皮子扬, 朱瑞琪, 等. 基于 WOA-BiLSTM 神经网络的风力发电预测[J]. 电工技术, 2022(10): 28-31.
- [13] JIA R, YANG G H, ZHENG H F, et al. A combined CNN-LSTM&GRU wind power prediction method based on adaptive weights[J]. China Electric Power, 2022, 55(5): 47-56, 110.
贾睿, 杨国华, 郑豪丰, 等. 基于自适应权重的 CNN-LSTM&GRU 组合风电功率预测方法[J]. 中国电力, 2022, 55(5): 47-56, 110.
- [14] ZHANG B, JIA M Q, XU J Z, et al. Network security situation prediction model based on EMD and ELPSO optimized BiGRU neural network [DB/OL]. <https://www.hindawi.com/journals/cin/2022/6031129/>.
- [15] TIAN Y J, GUO N W, XU D H, et al. Combining attention mechanism and BIM features for power energy consumption prediction[J]. Computer Applications and Software, 2021, 38(6): 39-45, 51.
田英杰, 郭乃网, 徐东辉, 等. 结合注意力机制与 BIM 特征的电力能耗预测[J]. 计算机应用与软件, 2021, 38(6): 39-45, 51.
- [16] CHEN Y J, CHENG G X. Short-term load forecasting based on SFO-GRU model [J]. Modern Information Technology, 2021, 5(4): 93-96, 99.
陈昱吉, 成贵学. 基于 SFO-GRU 模型的短期负荷预测[J]. 现代信息科技, 2021, 5(4): 93-96, 99.
- [17] QIU X G, WANG R Z, ZHANG W G, et al. A whale optimization algorithm based on hybrid policy improvement [J]. Computer Engineering and Applications, 2022, 58(1): 70-78.
秋兴国, 王瑞知, 张卫国, 等. 基于混合策略改进的鲸鱼优化算法[J]. 计算机工程与应用, 2022, 58(1): 70-78.
- [18] ZENG Y J, XIAO X Y, XU F W, et al. Short-term load forecasting method based on CNN-BiGRU-NN model [J]. China Electric Power, 2021, 54(9): 17-23.
曾圆钧, 肖先勇, 徐方维, 等. 基于 CNN-BiGRU-NN 模型的短期负荷预测方法[J]. 中国电力, 2021, 54(9): 17-23.
- [19] DANG Y. Short-term electric load forecasting based on improved whale algorithm and recurrent neural network [D]. Chengdu: Southwest Jiaotong University, 2019.
党雨. 基于改进鲸鱼算法和循环神经网络的短期电力负荷预测[D]. 成都: 西南交通大学, 2019.

(责任编辑:黄 健)