

DOI: 10.19783/j.cnki.pspc.231431

基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测

王延峰, 曹育晗, 孙军伟

(郑州轻工业大学, 河南省信息化电器重点实验室, 河南 郑州 450002)

摘要: 针对长短期记忆(long short term memory, LSTM)神经网络存在短期负荷预测精度低和稳定性差的问题, 提出一种基于多策略改进金豺(improved golden jackal optimization, IGJO)算法优化 LSTM 的短期电力负荷预测模型。首先融合凸透镜成像反向学习策略, 探索更好的初始解位置; 引入 Sigmoid 函数改变逃逸能量, 平衡探索和开发阶段; 融合鲸鱼优化算法的螺旋包围机制, 增强探索能力, 提高收敛精度。然后, 引入 LSTM 神经网络, 利用 IGJO 算法优化 LSTM 的超参数, 并建立 IGJO-LSTM 短期电力负荷预测模型。最后, 使用河南某地区的实际电力负荷数据验证 IGJO-LSTM 短期负荷预测模型。实验结果表明, 所提预测模型在工作日和周末不同时刻的电力系统短期负荷预测结果与实际负荷较接近。相比于传统预测方法, 所提预测模型具有更高的精确度和稳定性, 并具有一定的实际应用潜力。

关键词: 电力负荷预测; 长短时记忆网络; 凸透镜成像; 非线性逃逸能量; 螺旋包围机制

Short-term power load forecasting based on multi-strategy improved golden jackal algorithm-optimized LSTM

WANG Yanfeng, CAO Yuhang, SUN Junwei

(Henan Key Lab of Information-Based Electrical Appliances, Zhengzhou University of Light Industry, Zhengzhou 450002, China)

Abstract: There are problems of low accuracy and poor stability in short-term load forecasting using long short-term memory (LSTM) neural networks. Thus this paper proposes an improved golden jackal optimization (IGJO) algorithm to optimize the LSTM model. First, it integrates a convex lens reverse learning strategy for better starting positions. It introduces the sigmoid function to change the escape energy and balance exploration and development stage. It fuses whale optimization algorithm's spiral enclosure to improve exploration capability and convergence accuracy. Then, it introduces the LSTM neural network, and uses the IGJO algorithm to optimize its hyperparameters and to establish the IGJO-LSTM short-term electricity load forecasting model. Finally, the IGJO-LSTM short-term load forecasting model is validated using actual power load data from a region in Henan province. The experimental results show that the short-term load prediction results of the IGJO-LSTM model at different times on weekdays and weekends are closer to the actual load. Compared to traditional methods, it demonstrates higher accuracy and stability, indicating practical application potential.

This work is supported by the National Natural Science Foundation of China (No. 62272424 and No. 62276239).

Key words: electricity load forecasting; long-short-term memory networks; imaging of a convex lens; nonlinear escape energy; spiral envelope mechanism

0 引言

目前, 全国对电力供应的需求不断增加。电力公司需要对负荷预测相关数据进行综合分析, 制定高效经济的发电计划, 合理安排人员出力, 提供安

全稳定的电力。应尽量保证能源供需平衡, 防止能源生产过剩和电力供应不足^[1-2]。随着新型电力系统的逐步建立, 负荷结构不仅更加多样化, 而且用户与电网双方的联系也越来越多, 导致负荷特性更加复杂。因此, 负荷预测的要求也越来越高^[3-4]。

准确的电力负荷预测为长期电网建设投资和未来电力系统改造提供可靠依据。目前一些学者研究电力负荷的变化规律, 保证在一定准确性的前提

基金项目: 国家自然科学基金项目资助(62272424, 62276239); 国网河南省电力公司科技项目资助(5217S0240001)

下, 对未来一定时期内的电力负荷使用情况进行准确、科学的预测^[5]。其中短期负荷预测是针对未来几天或几周的预测, 其主要目的是保证电力能源合理供应, 提高电力系统的稳定性和安全性^[6]。从理论上讲, 负荷预测的核心问题是确定负荷变化的影响因素, 并分析各因素之间的关系, 通过建立相应的预测模型进行预测^[7]。

近年来, 深度学习发展迅速, 为短期电力负荷预测提供了思路^[8]。电力负荷具有高度动态性和非线性的特点, 传统的线性模型难以适应这种变化^[9]。长短期记忆(long short term memory, LSTM)神经网络因其出色捕捉非线性关系的能力而备受学者关注^[10]。然而, 在电力系统短期负荷预测中, 确定 LSTM 的参数是一个具有挑战性的问题^[11]。研究者采用算法对 LSTM 神经网络参数进行优化, 提高预测精度^[12]。通过对参数的优化, LSTM 神经网络可以更好地适应电力系统负荷的复杂非线性动态变化, 从而提高短期电力负荷预测精度, 对电力系统的可靠性和稳定性产生积极影响^[13-15]。

通过以上研究, 本文提出了一种基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测模型。首先融合凸透镜成像反向学习策略, 探索更好的初始解位置; 引入 Sigmoid 函数改变逃逸能量, 平衡探索和开发阶段; 融合鲸鱼优化算法的螺旋包围机制, 增强探索能力, 提高收敛精度。其次, 引入 LSTM 神经网络, 利用改进金豺(improved golden jackal optimization, IGJO)算法优化 LSTM 的超参数, 建立 IGJO-LSTM 短期电力负荷预测模型。最后通过对工作日和周末的电力负荷进行预测, 验证了 IGJO-LSTM 模型具有更高的精确度和稳定性。

1 长短时记忆网络的原理和步骤

LSTM 是在递归神经网络(recurrent neural networks, RNN)的基础上发展起来的, 以解决 RNN 处理长序列时的梯度消失和梯度爆炸问题^[16-18]。与 RNN 相比, LSTM 内部包含输入门、遗忘门、输出门、记忆单元以及信息传送单元, 从而实现在处理时序问题过程中对关键的信息进行记忆与更新^[19]。其结构如图 1 所示。

LSTM 神经网络的工作原理如下。

遗忘门: 决定 $t-1$ 时刻细胞中信息的保留和遗忘。相关公式如式(1)所示。

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

式中: f_t 为遗忘门参数; σ 为 Sigmoid 函数; W_f 为遗忘门权重; h_{t-1} 为 $t-1$ 时刻隐藏层输出信号; x_t 为

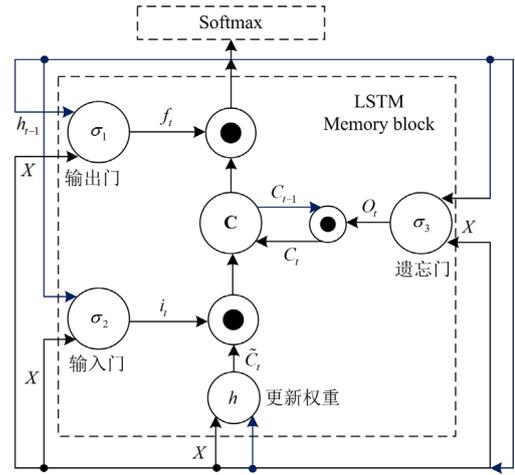


图 1 LSTM 内部结构原理图

Fig. 1 Schematic diagram of the internal structure of LSTM

输入信号; b_f 为遗忘门的偏置矩阵。

输入门: 用于确定哪些新信息可以输入到记忆单元中以更新细胞状态。相关公式如式(2)一式(4)所示。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

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

式中: i_t 为输入门参数; W_i 为输入门权重; W_c 为细胞状态权重; \tanh 为双曲正切激活函数; b_i 为输入门的偏置矩阵; b_c 为记忆单元的偏置矩阵; \tilde{C}_t 为记忆单元的输入状态; C_{t-1} 为 $t-1$ 时刻细胞状态; C_t 为当前细胞状态。

输出门: 用于过滤记忆单元中的信息, 并输出最需要的信息, 以预测未来的值。相关公式如式(5)一式(6)所示。

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

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

式中: O_t 为输出门参数; W_o 为细胞状态权重; b_o 为输出门的偏执矩阵; h_t 为 t 时刻隐藏层输出信号。

2 金豺优化算法

金豺优化(golden jackal optimization, GJO)算法是在 2022 年提出的一种元启发式算法^[20]。该算法是一种模仿金豺合作狩猎行为的新颖智能优化算法。在金豺组合中, 雄性金豺处于第一个领导者位置, 是最优的探索位置; 雌性金豺属于跟随者, 处于次优位置。在金豺优化算法中, 金豺的狩猎过程分为三个阶段: (1) 搜索猎物, 并逼近猎物; (2) 包

围猎物, 并刺激猎物直到停止运动; (3) 攻击猎物。

金豺种群定义了当前的最佳候选解是最靠近猎物的位置。最接近最优适应度值的为当前雄性金豺的位置, 金豺种群的位置模型用式(7)来描述。

$$Y_0 = l_b + rand \times (u_b - l_b) \quad (7)$$

式中: Y_0 为初始金豺种群的位置; $rand$ 是 (0,1) 范围内均匀分布的随机数; u_b 和 l_b 分别是求解问题的上下边界。

在猎物逃脱过程中, 逃逸能量 E 会随着猎物逃脱时间的增长呈线性变小, 直至能量减少为 0; 猎物的能量越少, 金豺就越容易捕捉到猎物。雄性和雌性金豺位置更新公式如下。

$$E = C_1 * (1 - (\frac{k}{T_{max}})) * (2r_1 - 1) \quad (8)$$

$$Y_1(k) = Y_M(k) - E \cdot |Y_M(k) - L \cdot p_{rey}(k)| \quad (9)$$

$$Y_2(k) = Y_{FM}(k) - E \cdot |Y_{FM}(k) - L \cdot p_{rey}(k)| \quad (10)$$

式中: C_1 的取值为 1.5; k 为当前迭代次数; T_{max} 为最大迭代次数; r_1 为 (0,1) 范围内均匀分布的随机数; $Y_1(k)$ 和 $Y_2(k)$ 分别为第 k 次迭代后与猎物相应的雄性和雌性金豺位置; $Y_M(k)$ 和 $Y_{FM}(k)$ 分别为第 k 次迭代雄性和雌性金豺的位置; L 为莱维分布中的随机数; $p_{rey}(k)$ 为第 k 次迭代猎物的位置。综上所述, 金豺的更新位置如式(11)所示。

$$Y(k+1) = \frac{Y_1(k) + Y_2(k)}{2} \quad (11)$$

金豺捕食组合对上一阶段检测到的猎物包围起来, 攻击并吞食猎物。雄性和雌性金豺捕猎行为的数学模型如下。

$$Y_3(k) = Y_M(k) - E \cdot |L \cdot Y_M(k) - p_{rey}(k)| \quad (12)$$

$$Y_4(k) = Y_{FM}(k) - E \cdot |L \cdot Y_{FM}(k) - p_{rey}(k)| \quad (13)$$

式中, $Y_3(k)$ 和 $Y_4(k)$ 分别为第 k 次迭代后与猎物相应的雄性和雌性金豺的位置。最后, 最优金豺的位置更新仍然按式(11)计算。

2 多策略改进金豺算法

2.1 凸透镜成像反向学习

金豺算法在求解优化问题时, 初始位置在某种程度上决定能否更准确、更迅速地寻找到最佳位置。凸透镜成像反向学习策略将其产生的反向个体与当前最优个体结合生成新的个体。凸透镜的成像过程原理如图 2 所示。

图 2 中, 选取 $[u_b, l_b]$ 的中点作为基点位置 O , 并在基点位置放置一个焦距为 F 的凸透镜。 P 为金

豺个体, P^* 为其倒像。全局最优个体 X 以 O 为基点, 其对应的反向个体 X^* , 根据凸透镜成像原理得

$$\frac{(u_b + l_b)/2 - X}{X^* - (u_b + l_b)/2} = \frac{h}{h^*} \quad (14)$$

$$X^* = \frac{u_b + l_b}{2} + \frac{u_b + l_b}{2 \cdot \partial} - \frac{X}{\partial} \quad (15)$$

式中: h 为物, h^* 为像, $h/h^* = \partial$ 表示物与像之间的对应比例关系, 其中 ∂ 为比例因子。

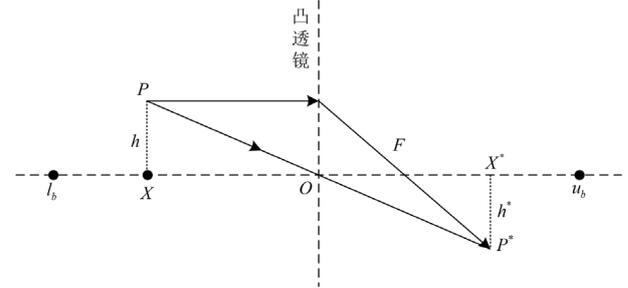


图 2 凸透镜成像反向学习原理图

Fig. 2 Convex lens imaging reverse learning schematic

在基本凸透镜成像反向学习中, 比例因子一般作为固定值进行使用, 容易陷入局部最优。本文提出一种基于动态递减的比例因子策略, 在迭代前期可以获得较大值, 使金豺可以在不同维度区域进行大范围的搜索, 提高群体的多样性; 在迭代后期获得较小值, 在最优个体附近进行精细搜索, 提高局部寻优能力。比例因子计算公式为

$$\partial = \partial_{max} - (\partial_{max} - \partial_{min}) \times (k/T_{max})^2 \quad (16)$$

式中, ∂_{max} 、 ∂_{min} 分别为最大和最小比例因子。

2.2 非线性逃逸能量

猎物的逃逸能量 E 是控制猎物位置更新的决定性因素, 负责平衡算法的全局搜索和局部开发行为。采用 Sigmoid 函数的非线性 s 型特征的变化方式可以持续地进行全局搜索找到最优区域, 从而改进前期收敛速度慢的缺点, 提高收敛速度。

$$E = E_0 \cdot (E_{min} + (E_{max} - E_{min}) \cdot f_s(x)) \quad (17)$$

$$f_s(x) = \frac{1}{1 + e^{-x}} \quad (18)$$

$$x = \lambda(2\frac{k}{M} - 1) \quad (19)$$

式中: E_0 为初始逃逸能量; E_{max} 、 E_{min} 分别为猎物最大、最小逃逸能量, $E_{min} = \frac{E_{max}}{10}$; $f_s(\cdot)$ 为 Sigmoid 函数; x 为非线性能量的取值范围; λ 为调节系数, $\lambda = 6$; M 为种群最大进化代数。

2.3 螺旋收缩包围策略

金豺算法通过模拟鲸鱼螺旋探索和包围猎物的

方式, 将鲸鱼优化算法的螺旋位置更新和收缩包围机制相融合, 建立螺旋包围更新方程, 加快金豺的搜索速度, 提高收敛精度。其计算公式如下。

$$\mathbf{X}(k+1) = D_2 \times e^{bl} \times \cos(2\pi l) + \mathbf{X}^*(k) \quad (20)$$

$$D_2 = |\mathbf{X}^*(k) - \mathbf{X}(k)| \quad (21)$$

$$l = (a_1 - 1) \times r_3 + 1 \quad (22)$$

$$a_1 = -1 - \frac{k}{T_{\max}} \quad (23)$$

式中: $\mathbf{X}(k+1)$ 是下一时刻的位置向量; $\mathbf{X}^*(k)$ 是目前得到最优解的位置向量; 每次迭代结果若有更好的解决方案, 即此时位置的适应度值小于 $\mathbf{X}^*(k)$ 的适应度值, 则将迭代得到的鲸鱼位置向量设置为新的最优位置向量; a_1 的取值范围为 $(0, 2)$, 且随着 k 的增加而线性改变; D_2 为猎物和金豺之间的距离; r_3 为 $(0, 1)$ 范围内均匀分布的随机数; b 为控制螺旋形状的参数, 本文设置为 1; l 的取值范围是 $[-2, 1]$ 。

2.3 最优邻域扰动

金豺在进行全局位置更新搜索时, 空间内所有的金豺向着最优位置寻找, 导致金豺在搜索过程中丧失多样性。因此在全局位置更新时, 对最优位置进行邻域扰动, 增强对其邻域空间的搜索, 使之能够在全局搜索时更好地跳出局部最优, 寻找到全局最优解, 避免算法早熟。最优邻域扰动公式为

$$\hat{x}_{(k)} = \begin{cases} x_{(k)}^* & rand_2 \geq 0.5 \\ x_{(k)}^* + rand_1 x_{(k)}^* & \text{else} \end{cases} \quad (24)$$

式中: $\hat{x}_{(k)}$ 为最优邻域扰动产生的新位置; $x_{(k)}^*$ 为全局更新时的最优位置; $rand_1$ 和 $rand_2$ 为 $[0, 1]$ 范围内均匀分布的随机数。

2.4 IGJO 函数性能测试

为了更加直观地表现出 IGJO 的整体性能, 将

IGJO 算法与基本 GJO 算法和其他寻优效果较好的原始算法如鲸鱼优化算法(whale optimization algorithm, WOA)^[21]、蚁狮优化算法(ant lion algorithm, ALO)^[22]、多元宇宙优化(multi-verse optimizer, MVO)算法^[23]和灰狼优化(grey wolf optimizer, GWO)算法^[24]进行比较, 对比算法参数均按照原文献设置, 种群数量为 30, 迭代次数为 500。测试函数^[25]见式(25), 其函数相关参数如表 1 所示。算法的数据对比如表 2 所示。

从表 2 可以看出, IGJO 算法的寻优效果最佳, 在 5 个函数中均找到最优值。其次是 GJO 算法、GWO 算法和 WOA 在两个函数中找到最优值。相比之下 MVO 算法的综合效果最差。

$$\begin{cases} F_1 = \sum_{i=1}^n x_i^2 \\ F_2 = \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \\ F_3 = \sum_{i=1}^n x_i^4 + rand[0, 1] \\ F_4 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10] \\ F_5 = -\sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1} \end{cases} \quad (25)$$

式中, $rand[0, 1]$ 为 $[0, 1]$ 范围内的随机数。

表 1 测试函数及相关参数

Table 1 Test functions and related parameters

	函数	范围	最小值
单模态函数	F_1	$[-100, 100]$	0
	F_2	$[-10, 10]$	0
多模态函数	F_3	$[-1.28, 1.28]$	0
	F_4	$[-5.12, 5.12]$	0
	F_5	$[0, 10]$	-10.5363

表 2 算法的数据对比

Table 2 Data comparison of algorithms

函数	算法					
	IGJO	GJO	WOA	ALO	MVO	GWO
F_1	0	7.93×10^{-58}	4.96×10^{-92}	2.08×10^{-4}	-1.05×10^1	9.05×10^{-30}
F_2	0	9.09×10^{-54}	4.75×10^{-58}	1.93×10^{-3}	4.17×10^{-1}	2.21×10^{-17}
F_3	0	7.39×10^{-5}	8.27×10^{-5}	2.93×10^{-2}	1.31×10^{-2}	3.75×10^{-4}
F_4	0	0	0	2.93×10^{-2}	7.93×10^1	5.68×10^{-14}
F_5	-1.05×10^1	-1.04×10^1	-7.47×10^0	-1.86×10^0	-5.21×10^0	-1.05×10^1

评价算法优劣的标准可以归为以下两种: 一种是在相同迭代次数下, 更好的适应度值代表最优; 另一种是在最大迭代次数下, 最先找到全局最优值,

则代表算法性能最好^[26]。图 3 和图 4 分别为单模态函数 F_1 和多模态函数 F_3 进行测试的收敛曲线图。由图 3 和图 4 可知, IGJO 算法均在最少的迭代次数找

到最优的适应度值。

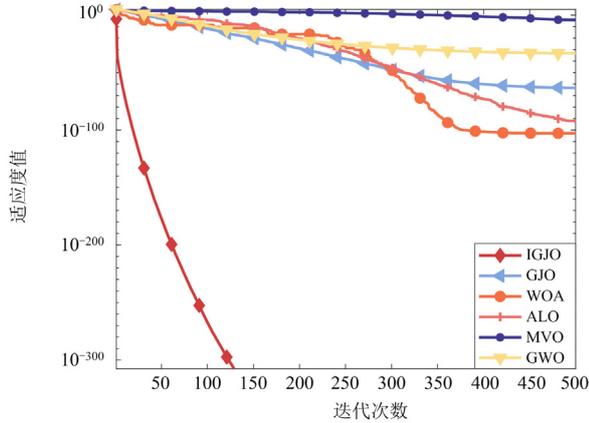


图 3 单模态函数适应度曲线

Fig. 3 Unimodal function fitness curves

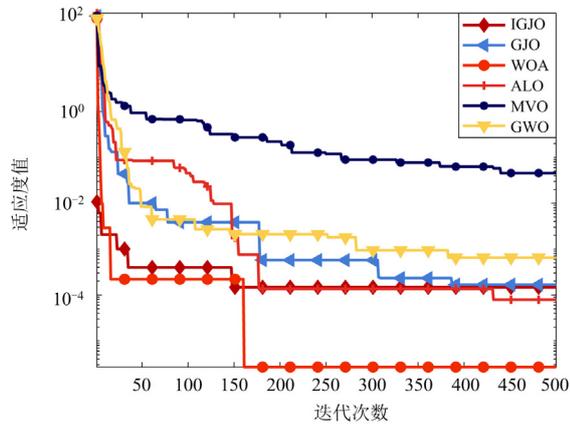


图 4 多模态函数适应度曲线

Fig. 4 Multimodal function fitness curves

3 IGJO 算法的 LSTM 负荷预测模型

在训练过程中发现 LSTM 网络的预测精度与超参数密切相关。本研究采用 IGJO 算法对 LSTM 网络进行优化, 建立 IGJO-LSTM 预测模型。采用 IGJO 算法对训练次数 K 、隐藏层神经元数 L_1 和 L_2 、学习率 l_r 三个参数进行优化, 找到最佳适应度值, 并将其赋予 LSTM 网络模型使其负荷预测的准确性得到进一步提高。

IGJO-LSTM 短期负荷预测模型的步骤具体如下, 流程图如图 5 所示。

Step 1: 将该地区的电力负荷数据进行量化和预处理, 并将其样本分为训练和测试样本。

Step 2: 设置金豺算法的相关参数, 利用凸透镜成像反向学习对种群位置进行初始化, 设定 LSTM 网络的训练次数、隐层神经元数和学习率。

Step 3: 根据式(17)更新非线性逃逸能量 E , 并计算莱维飞行中的参数 L , 计算比例因子 ρ 并且更新猎物的位置;

Step 4: 根据目标函数计算每个金豺个体的适应度值, 并对适应度值进行排序;

Step 5: 根据猎物非线性逃逸能量 E 是否小于 1 进行判断, 决定金豺使用螺旋包围机制或围攻机制进行位置更新, 雌性金豺跟随雄性金豺同时进行位置更新;

Step 6: 更新金豺当前位置并与当前位置适应度值进行比较得到最优适应度值;

Step 7: 对当前位置进行最优邻域扰动, 并使用贪婪策略机制进行判断, 若为最优位置则进行下一步, 否则重新进行 Step 2;

Step 8: 若当前迭代次数 k 小于最大迭代次数 T_{max} , 对当前迭代次数加 1, 并对当前结果进行逐维高斯变异后再次进入 Step 1, 否则输出最优解作为优化后的参数输入模型, 进行短期电力负荷预测。

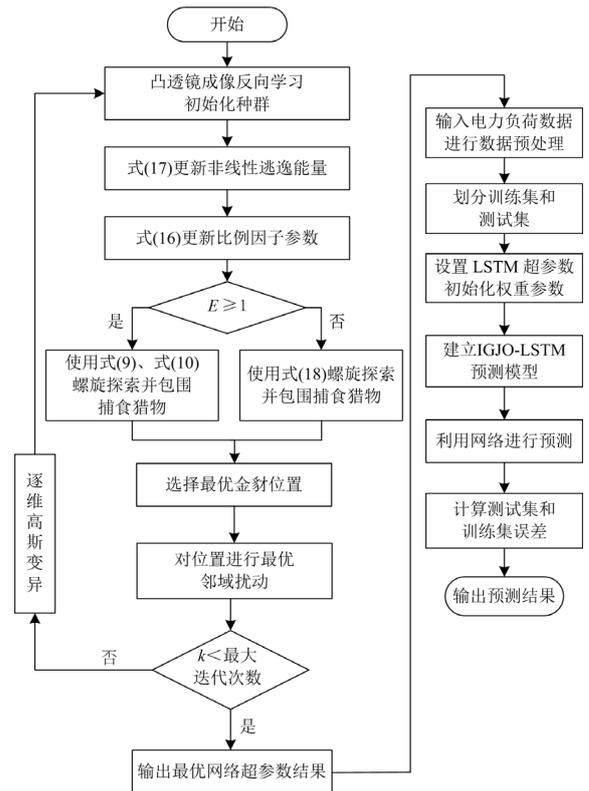


图 5 IGJO-LSTM 预测模型流程图

Fig. 5 Flowchart of the IGJO-LSTM prediction model

4 算例分析

本文基于河南某地区 2022 年 12 月 5 日至 2023 年 1 月 2 日的电力负荷数据和相关天气因素包括最高温度、最低温度、平均温度和相对湿度, 验证本

文所提 IGJO-LSTM 短期负荷预测模型的有效性和可靠性。采样周期为 15 min, 共 2688 条负荷数据。该模型充分考虑工作日和周末两种典型场景。

在本研究中, 选择采用直接式预测模式, 表示 IGJO-LSTM 模型将同时预测未来多个时间步的负荷值。通过采用直接式预测模式, 验证 IGJO-LSTM 模型在捕捉时间序列动态变化方面的表现, 全面评估 IGJO-LSTM 模型的性能。为保证负荷预测的精确度, 使用连续的负荷数据进行模型的训练和测试。具体而言, 从 4 周中任意选取 3 周工作日的 1440 条负荷数据作为训练集, 另一周工作日的 480 条数据则作为测试集。同样地, 选取任意 3 周周末的 576 条负荷数据作为训练集, 1 周周末的 192 条数据则作为测试集。为了评估 IGJO-LSTM 模型的性能, 与其他 6 种模型进行比较。

4.1 数据处理

为确保所得结果的有效性, 对 6 种优化算法 (GJO、WOA、MVO、ALO、GWO 和 IGJO) 进行相同的参数设置。实验中将训练集和测试集按 4:1 的比例分割, 设定 IGJO-LSTM 模型中隐藏层神经元数 $L_1, L_2 \in [1, 100]$, $K \in [1, 50]$, $l_r \in [0.001, 0.01]$ 。为了提高 LSTM 的训练速率, 对原始输入数据进行归一化处理, 如式(26)所示。

$$x_n = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad (26)$$

式中: x_n 为归一化数据源; x_0 为原始数据; x_{\max} 、 x_{\min} 分别为样本数据最大值和最小值。

为了避免随机性, 保证检验模型的有效性, 对所有模型均进行 30 次的独立运行。选取平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和各点误差相对值的均方根误差(root mean squared error, RMSE) 作为评价指标^[27], 分别对应为 M_{AE} 、 M_{APE} 和 R_{MSE} 。

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (27)$$

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |(\hat{y}_i - y_i)| \quad (28)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (29)$$

式中: y_i 为实际值; \hat{y}_i 为预测值; n 为测试集样本数量。

4.2 数据对比

表 3 为不同模型在预测周末电力负荷的结果对比。相较于其他算法优化的模型, 单一的 LSTM 预测精度效果最差, 而 LSTM 的超参数经过算法寻优

调整, 获得了较高的预测精度和稳定性。此外本文提出的模型在平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和各点误差相对值的均方根误差(RMSE)相对于其他 6 种模型均有明显降低。其中 MAE 指标分别降低 116.18 MW、31.21 MW、44.97 MW、18.63 MW、88.93 MW 和 60.05 MW。MAPE 指标分别降低 11.69%、1.89%、2.52%、0.94%、7.94%和 5.54%。RMSE 指标相较于 LSTM 模型降低了 85.69%, 与其他模型相比也有明显的降低。综上可知, 采用 IGJO-LSTM 对模型进行优化调整后, 预测准确度在一定程度上得到提高。本文所提预测模型相比其他预测模型在周末有更好的预测精度。

表 3 周末预测精度对比

Table 3 Comparison of weekend prediction accuracy

模型	$M_{APE}/\%$	M_{AE}/MW	R_{MSE}/MW
LSTM	15.43	137.51	240.64
GJO-LSTM	5.63	52.54	82.52
WOA-LSTM	6.26	66.27	139.37
MVO-LSTM	4.68	39.96	60.23
ALO-LSTM	11.68	110.26	179.01
GWO-LSTM	9.28	81.38	127.60
IGJO-LSTM	3.74	21.33	34.43

表 4 为不同模型在预测工作日预测精度的结果对比。相较于其他算法优化的模型, 单一的 LSTM 预测精度效果最差, 而 LSTM 的超参数经过算法寻优调整, 获得了较高的预测精度和稳定性。此外本文提出的模型在平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和各点误差相对值的均方根误差(RMSE)相对于其他 6 种模型均有明显降低。其中 MAE 指标分别降低 93.56 MW、24.45 MW、29.37 MW、13.68 MW、70.71 MW 和 47.45 MW。MAPE 指标分别降低 9.75%、1.14%、1.69%、0.95%、4.92%和 2.87%。RMSE 指标相较于 LSTM 模型降低 83.67%, 与其他模型相比也有明显降低。综上可知, 采用 IGJO-LSTM 对模型进行优化调整后, 预测准确度和稳定性得到很大提升。本文所提预测模型相比其他预测模型在工作日有更好的预测精度。

表 4 工作日预测精度对比

Table 4 Comparison of weekday prediction accuracy

模型	$M_{APE}/\%$	M_{AE}/MW	R_{MSE}/MW
LSTM	13.17	113.42	184.87
GJO-LSTM	4.83	44.28	70.54
WOA-LSTM	5.11	49.23	82.71
MVO-LSTM	4.37	33.54	53.60
ALO-LSTM	8.34	90.57	144.68
GWO-LSTM	6.29	67.31	109.84
IGJO-LSTM	3.42	19.86	30.19

负荷具有波动性, 特别是在用电高峰期时, 其负荷数据波动十分明显。周末的负荷值小于工作日, 并且周日负荷低于周六。该现象说明在不同日期类型的生活生产方式有着极大的不同, 导致需求的负荷量差异大。图 6 和图 7 均表明 IGJO-LSTM 模型与真实值的拟合效果最好, 异常波动性小于其他算法, 证明 IGJO-LSTM 模型的稳定性更好。

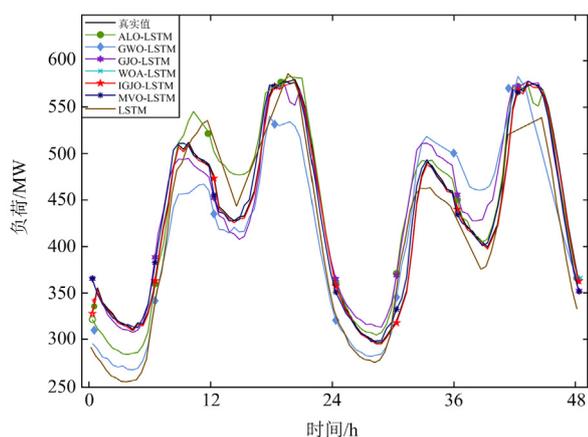


图 6 周末预测负荷结果对比图

Fig. 6 Comparison of forecast load results on weekends

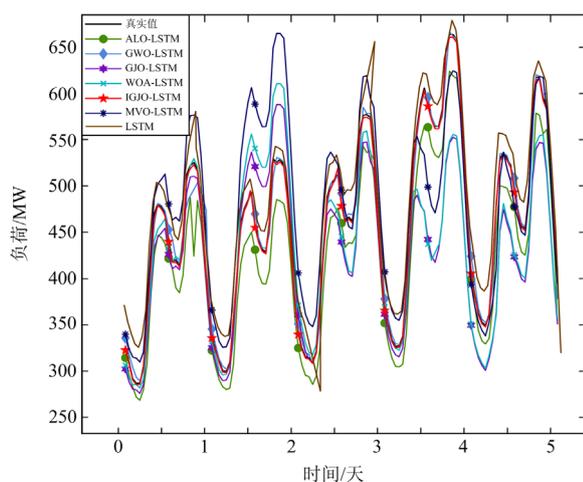


图 7 预测工作日负荷结果对比图

Fig. 7 Comparison of forecast weekday load results

5 结论

针对 LSTM 神经网络存在预测精度低和稳定性差的问题, 本文提出了一种基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测模型, 并得到以下结论:

1) 基于传统金豺收敛精度低的问题, 通过融合凸透镜成像反向学习策略, 探索更好的初始解位置。引入 Sigmoid 函数改变逃逸能量, 平衡探索和开发阶段。融合鲸鱼优化算法的螺旋包围机制, 增强探

索能力, 提高收敛精度。

2) 针对 LSTM 神经网络存在预测精度低和稳定性差的问题, 利用 IGJO 算法优化 LSTM 模型的隐藏层神经元和学习率的参数, 提高 LSTM 模型训练的效率 and 性能, 避免过拟合的风险, 确保其预测精度和稳定性。

3) 建立 IGJO-LSTM 负荷预测模型, 并使用中国某地区的实际负荷数据进行验证。实验结果表明, 所提预测模型在工作日和周末不同时刻的电力系统短期负荷预测结果与实际负荷较接近, 相比于传统预测方法具有更高的精确度和稳定性, 并具有一定的实际应用潜力。

参考文献

- [1] LI Ke, HUANG Wei, HU Gaoyuan, et al. Ultra-short term power load forecasting based on CEEMDAN-SE and LSTM neural network[J]. Energy Buildings, 2023, 279: 112666.
- [2] 刘文杰, 刘禾, 王英男, 等. 基于完整自适应噪声集成经验模态分解的 LSTM-Attention 网络短期电力负荷预测方法[J]. 电力建设, 2022, 43(2): 98-108.
LIU Wenjie, LIU He, WANG Yingnan, et al. Short-term power load forecasting method based on CEEMDAN and LSTM-Attention network[J]. Electric Power Construction, 2022, 43(2): 98-108.
- [3] 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.
- [4] YANG Feifei, FU Xeqian, YANG Qiang, et al. Decomposition strategy and attention-based long short-term memory network for multi-step ultra-short-term agricultural power load forecasting[J]. Expert Systems with Applications, 2024, 238: 122226.
- [5] ZHOU Jun, JIA Yubin, YONG Panxiao, et al. Robust deep Koopman model predictive load frequency control of interconnected power systems[J]. Electric Power Systems Research, 2024, 226: 109948.
- [6] 狄曙光, 刘峰, 孙建宇, 等. 基于改进 ABC 和 IDPC-MKELM 的短期电力负荷预测[J]. 智慧电力, 2022, 50(9): 74-81.
DI Shuguang, LIU Feng, SUN Jianyu, et al. Short term power load forecasting based on improved ABC and IDPC-MKELM[J]. Smart Power, 2022, 50(9): 74-81.
- [7] KHAN Z A, ULLAH A, HAQ I U, et al. Efficient short-term electricity load forecasting for effective energy management[J]. Sustainable Energy Technologies and Assessments, 2022, 53: 102337.
- [8] YAZICI I, BEYCA O F, DELEN D. Deep-learning-based short-term electricity load forecasting: a real case application[J]. Engineering Applications of Artificial Intelligence, 2022, 109: 104645.
- [9] 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.
ZHANG Shuqing, LI Jun, JIANG Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural

- network for short-term power load forecasting[J]. Power System Technology, 2022, 46(8): 3269-3279.
- [10] 胡威, 张新燕, 李振恩, 等. 基于优化的VMD-mRMR-LSTM模型的短期负荷预测[J]. 电力系统保护与控制, 2022, 50(1): 99-106.
HU Wei, ZHANG Xinyan, LI Zhen'en, et al. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model[J]. Power System Protection and Control, 2022, 50(1): 99-106.
- [11] 刘亚琿, 赵倩. 基于聚类经验模态分解的CNN-LSTM超短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4444-4451.
LIU Yahui, ZHAO Qian. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM[J]. Power System Technology, 2021, 45(11): 4444-4451.
- [12] 邹红波, 柴延辉, 杨钦贺, 等. 基于混合ISSA-LSTM的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2023, 51(19): 21-31.
ZOU Hongbo, CHAI Yanhui, YANG Qinhe, et al. Remaining useful life prediction of lithium-ion batteries based on hybrid ISSA-LSTM[J]. Power System Protection and Control, 2023, 51(19): 21-31.
- [13] 赵小强, 脱奔奔, 惠永永, 等. 基于ISTA-LSTM模型的间歇过程质量预测[J]. 控制与决策, 2023, 38(11): 3279-3289.
ZHAO Xiaoqiang, TUO Benben, HUI Yongyong, et al. Batch process quality prediction based on ISTA-LSTM model[J]. Control and Decision, 2023, 38(11): 3279-3289.
- [14] 李艳波, 尹锴, 陈俊硕, 等. 结合改进残差网络和Bi-LSTM的短期电力负荷预测[J]. 哈尔滨工业大学学报, 2023, 55(8): 79-86.
LI Yanbo, YIN Pu, CHEN Junshuo, et al. Short-term power load forecasting based on combination of residual network and Bi-LSTM[J]. Journal of Harbin Institute of Technology, 2023, 55(8): 79-86.
- [15] 钟劲松, 王少林, 冉懿, 等. 基于互信息和LSTM的用户负荷短期预测[J]. 电力建设, 2022, 43(7): 96-102.
ZHONG Jingsong, WANG Shaolin, RAN Yi, et al. Short-term consumer load forecasting based on mutual information and LSTM[J]. Electric Power Construction, 2022, 43(7): 96-102.
- [16] FENG Zhongkai, LUO Tao, NIU Wenjing, et al. A LSTM-based approximate dynamic programming method for hydropower reservoir operation optimization[J]. Journal of Hydrology, 2023, 625: 130018.
- [17] 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.
- [18] JAHANI A, ZARE K, KHANLI L M. Short-term load forecasting for microgrid energy management system using hybrid SPM-LSTM[J]. Sustainable Cities and Society, 2023, 98: 104775.
- [19] ABOU H M, BUKHARI S M S, ZAFAR M H, et al. COA-CNN-LSTM: coati optimization algorithm-based hybrid deep learning model for PV/wind power forecasting in smart grid applications[J]. Applied Energy, 2023, 349: 121638.
- [20] CHOPRA N, ANSARI M M. Golden jackal optimization: a novel nature-inspired optimizer for engineering applications[J]. Expert Systems with Applications, 2022, 198: 116924.
- [21] 张国治, 陈康, 方荣行, 等. 基于DGA与鲸鱼算法优化Logit Boost-决策树的变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(7): 63-72.
ZHANG Guozhi, CHEN Kang, FANG Rongxing, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a LogitBoost-decision tree[J]. Power System Protection and Control, 2023, 51(7): 63-72.
- [22] 王妍, 于浩文, 凌丹, 等. 基于改进蚁狮算法优化BP的轴承故障诊断[J]. 计算机集成制造系统, 2023, 11(10): 1-21.
WANG Yan, YU Haowen, LING Dan, et al. Optimization of BP for bearing fault diagnosis based on improved antlion algorithm[J]. Computer Integrated Manufacturing Systems, 2020, 11(10): 1-21.
- [23] 郑聪, 周海峰, 郑东强, 等. 基于改进多宇宙算法的主动配电网故障定位方法研究[J]. 电力系统保护与控制, 2023, 51(2): 169-179.
ZHENG Cong, ZHOU Haifeng, ZHENG Dongqiang, et al. An active distribution network fault location method based on improved multi-universe algorithm[J]. Power System Protection and Control, 2023, 51(2): 169-179.
- [24] 田书欣, 刘浪, 魏书荣, 等. 基于改进灰狼优化算法的配电网动态重构[J]. 电力系统保护与控制, 2021, 49(16): 1-11.
TIAN Suxin, LIU Lang, WEI Shurong, et al. Dynamic reconfiguration of a distribution network based on an improved grey wolf optimization algorithm[J]. Power System Protection and Control, 2021, 49(16): 1-11.
- [25] 杨海柱, 田馥铭, 张鹏, 等. 基于CEEMD-FE和AOA-LSSVM的短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(13): 126-133.
YANG Haizhuo, TIAN Fuming, ZHANG Peng, et al. Short-term load forecasting based on CEEMD-FE-AOA-LSSVM[J]. Power System Protection and Control, 2022, 50(13): 126-133.
- [26] 王延峰, 廖荣航, 梁恩豪, 等. 基于围攻机制的改进鲸鱼优化算法[J]. 控制与决策, 2023, 38(10): 2773-2782.
WANG Yanfeng, LIAO Ronghang, LIANG Enhao, et al. Improved whale optimization algorithm based on siege mechanism[J]. Control and Decision, 2023, 38(10): 2773-2782.
- [27] 顾清华, 姜秉佼, 常朝朝, 等. 求解大规模优化问题的改进麻雀搜索算法[J]. 控制与决策, 2023, 38(7): 1960-1968.
GU Qinghua, JIANG Bingjiao, CHANG Zhaozhao, et al. An improved sparrow search algorithm for solving large-scale optimization problems[J]. Control and Decision, 2023, 38(7): 1960-1968.

收稿日期: 2023-11-08; 修回日期: 2024-01-08

作者简介:

王延峰(1973—), 男, 博士, 教授, 研究方向为仿生计算和数据处理; E-mail: yanfengwang@yeah.net

曹育晗(1999—), 男, 硕士研究生, 研究方向为大数据和群智能算法; E-mail: yuhancao2022@163.com

孙军伟(1984—), 男, 博士, 教授, 研究方向为智能算法及数据处理。E-mail: junweisun@yeah.net

(编辑 魏小丽)