

DOI:10.19651/j.cnki.emt.2209076

# 基于 ICOA-LSTM 的短期负荷预测研究<sup>\*</sup>

高超<sup>1</sup> 孙谊娟<sup>1,2</sup> 赵洪峰<sup>1</sup> 曹培芳<sup>1</sup>

(1. 新疆大学电气工程学院 乌鲁木齐 830017; 2. 国网新疆电力公司 乌鲁木齐 830017)

**摘要:** 精准的负荷预测有利于电力系统的稳定运行,提高经济性和可靠性。为了提高短期电力负荷的预测精度,提出了一种基于改进型黑猩猩算法优化长短时记忆网络的短期负荷预测模型。由于黑猩猩优化算法存在易陷入局部最优、寻优精度低等缺陷,采用 Circle 映射策略初始化种群,产生分布均匀的黑猩猩种群,提高黑猩猩种群的多样性,为全局寻优奠定基础;其次,引入螺旋位置更新策略,使黑猩猩种群有多种搜索路径,扩大搜索空间,提高种群的全局搜索能力;然后,引入 Levy 飞行策略和自适应  $t$  变异策略,在最优解位置进行扰动变异,增强抗局部极值能力,提高算法的收敛精度。针对 LSTM 网络的隐含层神经元数,学习率等参数较难选取的问题,利用 ICOA 对 LSTM 网络自动寻找最优参数,建立 ICOA-LSTM 负荷预测模型。结合某地区的实际数据进行预测分析,结果表明,与 BP、LSTM、PSO-LSTM、COA-LSTM 预测方法相比,ICOA-LSTM 模型具有更高的短期电力负荷预测精度,其预测平均绝对误差为 17.01 kW,均方根误差为 21.80 kW,平均绝对百分比误差为 0.37%。

**关键词:** 短期负荷预测;黑猩猩优化算法;Circle 映射;螺旋位置更新策略;Levy 飞行;自适应  $t$  变异;LSTM;最优参数

中图分类号: TM714 文献标识码: A 国家标准学科分类代码: 470.40

## Research on short-term load forecasting based on ICOA-LSTM

Gao Chao<sup>1</sup> Sun Yiqian<sup>1,2</sup> Zhao Hongfeng<sup>1</sup> Cao Peifang<sup>1</sup>

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830017, China;

2. Department of State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830017, China)

**Abstract:** Accurate load forecasting is beneficial to the stable operation of the power system, improving economy and reliability. In order to improve the short-term power load forecasting accuracy, a short-term load forecasting model based on the improved chimp optimization algorithm to optimize long-short-term memory network is proposed. Because the chimp optimization algorithm is prone to fall into local optimum and has low optimization accuracy, the Circle mapping strategy is used to initialize the population to generate a uniformly distributed chimp population, improve the diversity of the chimp population, and lay the foundation for global optimization. Secondly, the introduction of a spiral position update strategy enables the chimp population to have multiple search paths, expand the search space, and improve the global search ability of the population. Then, the Levy flight strategy and the adaptive  $t$  mutation strategy are introduced to perform disturbance mutation at the optimal solution position to enhance resistance to local extremes. It can improve the convergence accuracy of the algorithm. Aiming at the problem that parameters such as the number of hidden layer neurons and the learning rate of the LSTM network are difficult to select, ICOA is used to automatically find the optimal parameters for the LSTM network, and an ICOA-LSTM load prediction model is established. Combined with the actual data of a certain area, the prediction analysis is carried out. The results show that compared with the BP, LSTM, PSO-LSTM, and COA-LSTM prediction methods, ICOA-LSTM model has higher short-term power load forecasting accuracy, its forecast mean absolute error is 17.01 kW, the root mean square error is 21.80 kW, and the mean absolute percentage error is 0.37%.

**Keywords:** short-term load forecasting; chimp optimization algorithm; Circle chaos; spiral position update strategy; Levy flight; self-adaptive  $t$ -variation; LSTM; optimal parameters

## 0 引言

电力负荷预测是大智能电网安全稳定运行的一个重要

环节。电力负荷预测按照时间区间可分为长期、中期、短期 3 种,其中短期电力负荷预测的时间长度为几小时或几天。

发电企业可以依据精准的短期电力负荷预测结果,制定出

收稿日期:2022-02-24

\*基金项目:国家自然科学基金(51762038)项目资助

最优的发电计划,同时电力调度部门也能依据预测结果为系统的正常运行做出合理的规划,所以提高短期电力负荷预测精度对于电力企业具有重要意义,同时也对短期负荷预测方法的要求越来越高<sup>[1-2]</sup>。

电力负荷信号具有随机性、非平稳性等特点,这些特点直接影响了负荷预测精度。目前,传统的时间序列法、回归分析法等预测方法很难高度拟合非线性、多因素的电力负荷数据。智能预测算法能够拟合复杂的非线性数据,自适应能力强、鲁棒性强,如 LSTM<sup>[3-5]</sup>、BP<sup>[6-7]</sup>等方法。如文献[8]采用了 BP 神经网络对实际电站的数据进行了预测,但是未考虑 BP 网络泛化能力差和容易陷入局部最优解的问题。而且相较于 BP,LSTM 在对长时间序列的处理上,能够避免长时间依赖于输入序列的缺点,可以有效地根据历史信息进行学习和预测,获得更好的预测效果<sup>[9]</sup>。文献[10]将单隐含层的 LSTM 运用到短期负荷预测中,有效解决了在长序列中出现的梯度消失或爆炸缺陷等问题。然而 LSTM 面临着隐含层神经元的个数、学习率、迭代次数等超参数设置的问题,这些参数直接影响 LSTM 的预测精度。通常,大家多采用经验法对 LSTM 的超参数进行设置,需要通过多次尝试,找到效果比较好的一组,耗时耗力,该类方法不具有科学性,而且预测精度不能得到保障。

鉴于上述单一模型存在的问题,国内外学者提出了众多的组合预测模型。文献[11]采用花授粉算法优化 BP 网络的权值和阈值,提高了短期负荷预测精度。文献[12]采用网格搜索算法寻找 LSTM 网络的最优超参数。文献[13]利用粒子群算法优化 LSTM 网络输入权重,建立了 PSO-LSTM 短期电价预测模型。但是文献[11-13]未考虑算法陷入局部最优值的问题。文献[14]考虑到惯性权重对 PSO 算法收敛速度和收敛精度的影响,采用非线性惯性权重改进的 PSO 算法对 LSTM 超参数寻优,建立 IPSO-LSTM 负荷预测模型。

为了解决 LSTM 网络的超参数难以选定而导致的短期电力负荷预测精度不佳的问题,本文利用改进的黑猩猩算法对 LSTM 网络的超参数寻优,建立 ICOA-LSTM 负荷预测模型。相比于网格搜索算法、粒子群算法,黑猩猩优化算法拥有更好的搜索精度与收敛速度,但是在迭代过程中存在容易陷入局部最优解的问题。本文利用 Circle 混沌映射策略对种群进行初始化,克服种群初始化的盲目性,丰富黑猩猩种群的多样性,提高初始解的质量;采用螺旋搜索策略来扩大黑猩猩种群的空间搜索范围,提高种群的全局搜索能力;引入 Levy 飞行策略和自适应  $t$  变异策略,针对最优黑猩猩位置进行动态概率的切换扰动,提高其跳出局部最优解的能力,提高算法的收敛精度;利用改进的黑猩猩算法(ICOA)对 LSTM 的隐含层神经元数,学习率等超参数寻优,最后建立 ICOA-LSTM 的负荷预测模型。通过算例结果分析表明,本文所提出的模型具有良好的鲁棒性和预测精度,验证了所提方法的可行性和预测效果。

## 1 长短时记忆网络

长短时记忆网络作为一种改进的递归神经网络,其在 RNN 的基础上增加了遗忘门、输入门和输出门等 3 个门控单元,有效解决了 RNN 在长序列中出现的梯度消失或爆炸缺陷等问题。LSTM 依据独特的门控单元和记忆单元可以对长时间序列进行有效处理,克服了长时间依赖于输入序列的问题。遗忘门在保留了重要信息的同时避免了无用信息向后传递,而输入门和输出门则读取数据和将处理后的数据向下一个时刻传递<sup>[15]</sup>。LSTM 的结构如图 1 所示,其计算公式如式(1)~(6)所示。

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (2)$$

$$g_t = \tanh(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \quad (3)$$

$$O_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (4)$$

$$C_t = g_t * i_t + C_{t-1} * f_t \quad (5)$$

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

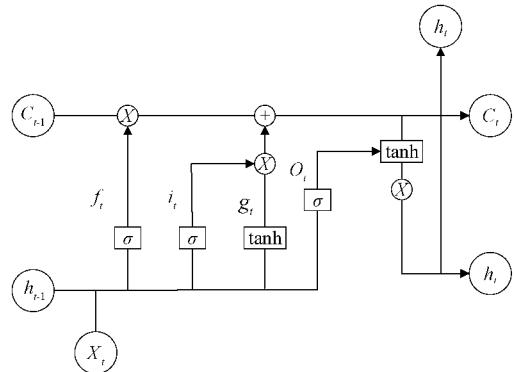


图 1 LSTM 结构

## 2 黑猩猩算法及改进

### 2.1 黑猩猩优化算法

黑猩猩算法主要模拟了黑猩猩对于猎物的攻击、驱赶、拦截和追逐等 4 种社会行为<sup>[16]</sup>。黑猩猩优化算法的基本描述为:假定黑猩猩种群数目为  $N$ ,  $X_i$  表示第  $i$  只黑猩猩所处的位置,群体的最优解为  $X_{attractor}$ 、次优解  $X_{barrier}$ 、第 3 优解  $X_{chaser}$ 、第 4 优解  $X_{drive}$ 。黑猩猩算法的具体数学描述如下:

1) 驱赶、追逐猎物。在黑猩猩狩猎的过程中,任何个体均会依据猎物的位置而改变自身的位置。其位置更新公式如下:

$$D = |C \cdot X_{prey}(t) - mX_{chimp}(t)| \quad (7)$$

$$X_{chimp}(t+1) = X_{prey}(t) - A \cdot D \quad (8)$$

$$A = f(2r_1 - 1) \quad (9)$$

$$C = 2r_2 \quad (10)$$

$$f = 2(1 - (t/t_{max})) \quad (11)$$

式中: $D$  表示黑猩猩与猎物之间的距离; $X_{prey}$  和  $X_{chimp}$  分

别表示猎物的位置和黑猩猩的位置;  $\mathbf{A}$ 、 $\mathbf{m}$ 、 $\mathbf{C}$  为系数向量,  $\mathbf{m} = Chaotic\_value$  是一个基于某种混沌映射计算出来的混沌向量;  $r_1$  和  $r_2$  为  $[0, 1]$  之间的随机数;  $t$  和  $t_{max}$  分别表示当前迭代次数和最大迭代次数;  $f$  为收敛因子, 在迭代过程中从 2 线性递减到 0。

2) 攻击方式。黑猩猩通过对猎物位置的探索, 最后将其包围。通常狩猎过程由攻击者进行, 而驱赶者、拦截者、追逐者仅参与狩猎过程, 4 种黑猩猩分别更新自己的位置, 其他黑猩猩根据四者的位置进行更新。

$$\left\{ \begin{array}{l} D_{attacker} = | C_1 \cdot X_{attacker} - m_1 \cdot X | \\ D_{barrier} = | C_2 \cdot X_{barrier} - m_2 \cdot X | \\ D_{chaser} = | C_3 \cdot X_{chaser} - m_3 \cdot X | \\ D_{drive} = | C_4 \cdot X_{drive} - m_4 \cdot X | \end{array} \right. \quad (12)$$

$$\left\{ \begin{array}{l} X_1 = X_{attacker} - A_1 \cdot D_{attacker} \\ X_2 = X_{barrier} - A_2 \cdot D_{barrier} \\ X_3 = X_{chaser} - A_3 \cdot D_{chaser} \\ X_4 = X_{drive} - A_4 \cdot D_{drive} \end{array} \right. \quad (13)$$

$$X(t+1) = (X_1 + X_2 + X_3 + X_4) / 4 \quad (14)$$

## 2.2 黑猩猩优化算法的改进

### 1) Circle 混沌映射初始化种群

在标准的黑猩猩算法中采用随机初始化种群, 有可能出现黑猩猩个体的分布不均匀, 从而陷入局部最优, 影响寻优精度效率。混沌映射模型常用于优化搜索问题, logistic 映射、Sin 映射和 Circle 映射是最常用的混沌模型。其中 Circle 映射结构简单, 映射呈现的结果分布密度比较均匀, 具有很好的遍历性<sup>[17-18]</sup>。利用 Circle 映射策略对种群进行初始化, 克服种群初始化的盲目性, 产生分布均匀的种群, 提高黑猩猩种群的多样性, 为后期黑猩猩算法寻优奠定基础。Circle 映射的定义如下:

$$x_{k+1} = \text{mod}[x_k + b - (a/2\pi)\sin(2\pi x_k), 1] \quad (15)$$

式中: mod 为取余函数,  $a, b$  为系数, 分别取值 0.5 和 0.2。

将随机方式、logistic 映射、Sin 映射和 Circle 映射归一化处理, 在  $[0, 1]$  区间内生成的黑猩猩种群如图 2 所示。从图 2 可以看出, 相较于随机方式、logistic 映射、Sin 映射, 利用 Circle 映射初始化黑猩猩种群, 未出现重叠现象, 黑猩猩个体分布的更加均匀, 扩大了黑猩猩种群的搜索空间, 在一定程度上避免了算法陷入局部极值的情况, 进而提高算法的寻优效率。

### 2) 螺旋更新位置模型

在标准 COA 中, 黑猩猩种群围绕着攻击者、驱赶者、拦截者、追逐者进行更新位置, 搜索路径相对单一。受鲸鱼算法<sup>[19]</sup>螺旋搜索的启发, 本文在攻击者、驱赶者、拦截者、追逐者的位置更新方式中加入一种螺旋搜索因子, 使得这 4 类黑猩猩有多种搜索路径来更好的调整位置, 扩大黑猩猩种群的空间搜索范围, 更有助于搜索到全局最优解, 进而提高算法的全局搜索能力。具有螺旋探索性能的位置更新公式为:

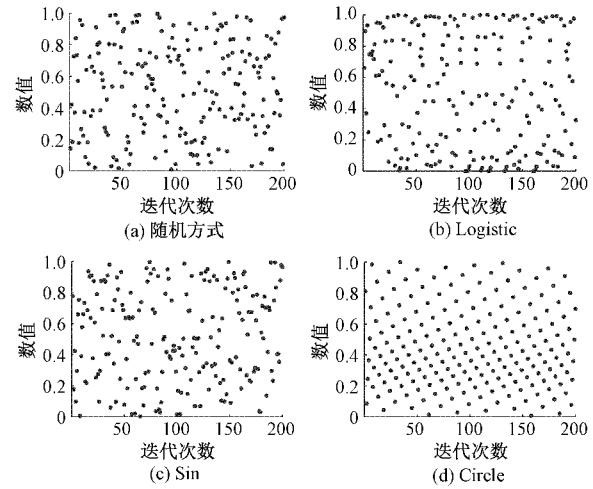


图 2 不同方法产生的初始化种群分布图

$$\left\{ \begin{array}{l} X_1 = X_{attacker} + D_{attacker} \cdot e^{bl} \cos(2\pi l) \eta \\ X_2 = X_{barrier} + D_{barrier} \cdot e^{bl} \cos(2\pi l) \eta \\ X_3 = X_{chaser} + D_{chaser} \cdot e^{bl} \cos(2\pi l) \eta \\ X_4 = X_{drive} + D_{drive} \cdot e^{bl} \cos(2\pi l) \eta \end{array} \right. \quad (16)$$

$$\eta = a - a(t/t_{max})^2$$

式中:  $t$  和  $t_{max}$  分别表示当前迭代次数和最大迭代次数,  $\eta$  控制余弦局部探索的范围, 随着迭代次数的增加而减小, 逐渐缩小余弦的搜索范围,  $a$  为常数, 本文中  $a$  取 1,  $b$  为螺旋形状系数,  $l$  表示路径系数, 为  $[0, 1]$  之间的随机数。

### 3) 动态概率切换的 Levy 飞行和自适应 $t$ 变异策略

Levy 飞行是法国数学家莱维依据自然界中很多动物在未知的环境中找到食物的方式所提出的一种搜索策略。在这种搜索模式下, 短距离的探索与较长距离行走相间, 短距离的探索可以保证动物在觅食过程中进行小范围的细致搜寻, 而较长距离的行走能够使自身进入下一个区域, 该模式保证了动物可以在不确定的环境中尽可能的搜索空间<sup>[20]</sup>。Levy 飞行的数学模型如式(17)所示。

$$\left\{ \begin{array}{l} Levy(\lambda) = \frac{\mu \times \sigma}{|\nu|^{1/\beta}} \\ \mu \sim N(0, \sigma_\mu^2), \nu \sim N(0, \nu_\mu^2), \nu = 1 \\ \sigma_\mu = \left( \frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right) \end{array} \right. \quad (17)$$

式中:  $\beta$  是一个常数, 决定 Levy 函数的形状, 文中取 1.5。将 Levy 飞行策略引入黑猩猩算法, 则有:

$$X'_{best} = X_{best} + \alpha \oplus Levy(\lambda) X_{best} \quad (18)$$

式中:  $X_{best}$  表示当前最优黑猩猩  $X_{attacker}$  的位置,  $X'_{best}$  为 Levy 飞行扰动后的黑猩猩  $X_{attacker}$  的位置,  $Levy(\lambda)$  表示飞行路径,  $\oplus$  为点对点乘法,  $\alpha$  为步长控制参数, 取值为 1。

自适应  $t$  分布又称为学生分布, 含有参数自由度  $n$ ,  $n$  的值越小, 其曲线形态越平坦, 曲线中间越低, 曲线双侧尾部翘得越高<sup>[21]</sup>。本文充分利用黑猩猩的种群信息, 以迭代次数  $t$  作为自由度参数, 在迭代前期  $t$  较小, 类似柯西变异

具有较强的全局搜索能力, 后期  $t$  较大, 类似高斯变异具有较强的局部搜索能力, 从而提高算法的搜索能力<sup>[22]</sup>。将自适应  $t$  分布策略引入黑猩猩算法, 则有:

$$X''_{best} = X_{best} + X_{best} \cdot trnd(iter) \quad (19)$$

式中:  $X_{best}$  表示当前最优黑猩猩  $X_{attacker}$  的位置,  $X''_{best}$  为自适应  $t$  变异扰动后的黑猩猩  $X_{attacker}$  的位置,  $trnd(iter)$  为以黑猩猩算法迭代次数为参数自由度的  $t$  分布。

为了解决黑猩猩算法在迭代后期陷入局部最优值和收敛精度不高的问题, 引入 Levy 飞行策略和自适应  $t$  变异策略, 针对最优黑猩猩位置进行动态概率的切换扰动, 提高其跳出局部最优解的能力, 提高算法的收敛精度。两种方式的选择, 如式(20)、(21)所示。

$$U_{best} = \begin{cases} X'_{best}, & P < z \\ X''_{best}, & \text{其他} \end{cases} \quad (20)$$

$$P = 0.6 - 0.1 \left( \frac{t_{\max} - t}{t_{\max}} \right)^2 \quad (21)$$

式中:  $U_{best}$  表示两种方式选择后更新的目标位置,  $z$  表示

$[0,1]$  之间的随机数,  $t$  和  $t_{\max}$  分别表示当前迭代次数和最大迭代次数。当  $P < z$  时, 选择 Levy 飞行策略, 对最优黑猩猩位置进行扰动, 反之选择自适应  $t$  变异策略。为保证适应度值的最优, 在变异更新后, 引入贪心机制, 对比变异前后两个位置的适应度值, 确定是否要更新位置。贪心机制如式(22)所示,  $f(x)$  表示黑猩猩个体在  $x$  处的适应度值。

$$X_{best} = \begin{cases} U_{best}, & f(U_{best}) < f(X_{best}) \\ X_{best}, & \text{其他} \end{cases} \quad (22)$$

#### 4) ICOA 算法性能测试

为测试 ICOA 的优化性能, 本文对 ICOA 与 COA 采用表 1 的基准测试函数进行测试。表 1 中  $f_1 \sim f_3$  为 3 个单模态测试函数, 用来测试算法的局部开发能力,  $f_4 \sim f_6$  为 3 个多模态测试函数, 用来测试算法的全局搜索能力和收敛速度, 其中单峰和多峰函数的维度均为 30。各算法的种群数量为 30, 迭代次数为 1 000, 在独立运行 30 次记录最优解的最优值、平均值和标准差衡量算法的性能, 其测试结果如表 2 所示, 各函数的收敛曲线如图 3 所示。

表 1 基准测试函数

函数	维度	搜索空间	理论值
$f_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100,100]$	0
$f_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	30	$[-100,100]$	0
$f_3(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30	$[-100,100]$	0
$f_4(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-100,100]$	0
$f_5(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	$[-100,100]$	0
$f_6(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-100,100]$	0

由表 2 可知, 对于单模态测试函数  $f_1 \sim f_3$ , 相较于 COA 算法, ICOA 在  $f_1$  上达到理论最优值, 在  $f_2$  上的最优值接近理论最优值, 且标准差接近 0, 对于函数  $f_3$ , 虽然 ICOA 的寻优效果不是特别理想, 但是依旧胜于 COA 算法, 表现出 ICOA 具有更强的局部挖掘能力。对于多模态测试函数  $f_4 \sim f_6$ , 在函数  $f_4$  和  $f_5$  上, ICOA 的平均值、标准差及最优值均为 0; 在  $f_6$  函数上, ICOA 的性能仍然优于 COA 算法。从多模态测试函数的测试结果来看, ICOA 具有更强的全局收敛能力, 而且还具有更强的收敛速度。由图 3 可知, 在求解不同模态测试函数时, ICOA 算法的收敛速度更快, 寻优精度更高。综上所述, ICOA 相较于 COA 算法, 不仅拥有更好的局部收敛性和全局探索能力, 从多次寻优的平均值和标准差可以看出, ICOA 的值更小, 表明了 ICOA 的稳定性和鲁棒性明显优于 COA 算法。

### 3 基于 ICOA-LSTM 负荷预测模型的建立

本文选择的 LSTM 模型为双层结构, 有 4 个参数对算法的性能有着重要影响, 分别为隐含层神经元的个数  $L_1$  和  $L_2$ , 学习率  $lr$ , LSTM 的迭代次数  $K$ ; 将这 4 个超参数作为 ICOA 算法寻优的特征, 即在 ICOA 算法中黑猩猩  $X$  为  $(L_{1i}, L_{2i}, lr_i, K_i)$ , 利用 ICOA 算法对 LSTM 模型进行优化。LSTM 前一层的输出作为下一层的输入, LSTM 层后面加入一个 Dropout 层, 增强 LSTM 的泛化性, 防止过拟合, 最后通过 dense 全连接层输出数据<sup>[23-24]</sup>。本文构建的模型 ICOA-LSTM 短期电力负荷预测具体步骤为:

1) 按照式(23)对原始数据  $x$  进行归一化处理, 划分训练集和测试集。

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (23)$$

表 2 测试结果

函数	评价指标	COA	ICOA
$f_1(x)$	最优值	$2.7633 \times 10^{-27}$	0
	平均值	$3.1050 \times 10^{-16}$	0
	标准差	0.0461	0
$f_2(x)$	最优值	$2.2528 \times 10^{-19}$	$1.9551 \times 10^{-169}$
	平均值	$4.5704 \times 10^{-13}$	$2.0941 \times 10^{-113}$
	标准差	$8.8355 \times 10^{-13}$	$1.1469 \times 10^{-142}$
$f_3(x)$	最优值	2.8699	0.0066
	平均值	3.9191	0.1112
	标准差	0.5060	0.1102
$f_4(x)$	最优值	0	0
	平均值	0.8803	0
	标准差	1.7219	0
$f_5(x)$	最优值	0	0
	平均值	0.0139	0
	标准差	0.0222	0
$f_6(x)$	最优值	0.2169	0.0107
	平均值	0.2909	0.0240
	标准差	0.1799	0.0102

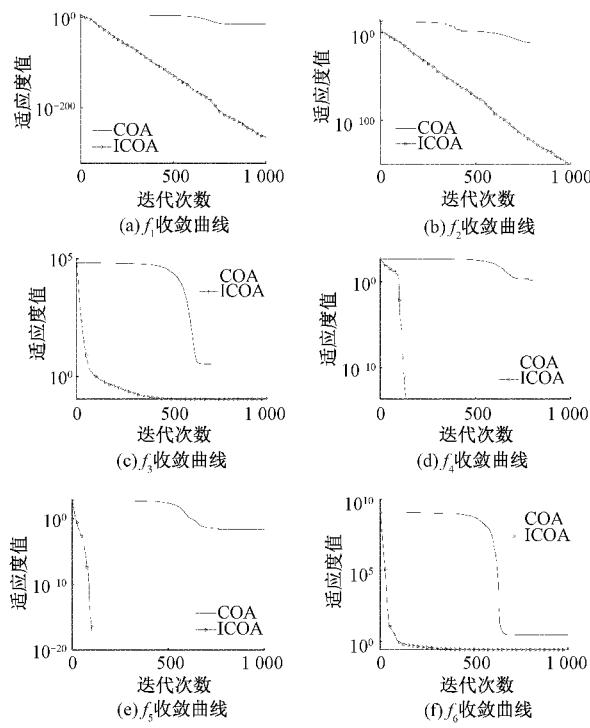


图 3 测试函数收敛曲线

式中:  $x_n$  为归一化后的数值,  $x_{\max}, x_{\min}$  为原数据中的最大、最小值。

2) 定义适应度。将 LSTM 网络预测值的均方差作为黑猩猩适应度值  $fit$ 。

$$fit = \frac{1}{n} \sum (y' - y)^2 \quad (24)$$

式中:  $n$  为负荷测试集数据的个数,  $y'$  为第  $i$  个预测数据的预测值,  $y$  为第  $i$  个测试数据的真实值。

3) 构建 LSTM 短期负荷预测模型, 确定参数的寻优范围。生成一个黑猩猩种群, 并利用 Circle 混沌映射初始化黑猩猩种群。将 LSTM 网络的隐含层神经元的个数  $L_1$  和  $L_2$ , 学习率  $lr$ , LSTM 的迭代次数  $K$  作为参数变量, 确定参数的寻优范围。

4) 计算所有黑猩猩个体的适应度值, 并按照从小到大的顺序进行排序, 确定当前最优解  $X_{\text{attacker}}$ 。

5) 依据式(12)、(14)、(16)更新黑猩猩的位置, 依据式(20)选择 Levy 飞行策略和自适应  $t$  变异策略, 并对当前最优解进行扰动, 产生最新解; 再根据式(20)确定是否进行位置更新。

6) 判断是否达到最大迭代次数  $t_{\max}$ , 若未达到, 转向步骤 3); 反之, 则将最优参数赋予 LSTM 并进行训练, 输出短期负荷预测值。

#### 4 实例分析

选取美国纽约某地区 2020 年 4 月的电力负荷数据, 数据的周期为 5 min, 每天产生 288 组负荷数据, 共计 8 640 个数据点, 将前 8 352 个数据作为训练集, 后 288 个数据作为预测集。为了定量分析所得到的预测结果, 选取的评价指标为平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE)、均方根误差 (RMSE)。评价指标的定义式为:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (25)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (26)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (27)$$

式中:  $N$  为电力负荷预测集数据的个数,  $\hat{y}_i$  为第  $i$  个预测数据的预测值,  $y_i$  为第  $i$  个预测数据的真实值。

为了测试 LSTM 模型的性能, 选取 BP 和 LSTM 进行比较。相关参数设置为: BP 与 LSTM1 的网络结构设为 36-100-100-1, 学习率为 0.005, 迭代次数为 100; LSTM2 的网络结构为 36-150-100-1, 学习率为 0.01, 迭代次数为 50; 预测结果如图 4 所示, 预测误差如表 3 所示。

表 3 预测结果评价值

预测模型	MAE/kW	MAPE/%	RMSE/kW
BP	38.50	0.83	50.24
LSTM1	32.33	0.71	38.52
LSTM2	65.98	1.43	72.81

从图 4 和表 3 可以看出, 在单一的预测模型中, 相较于

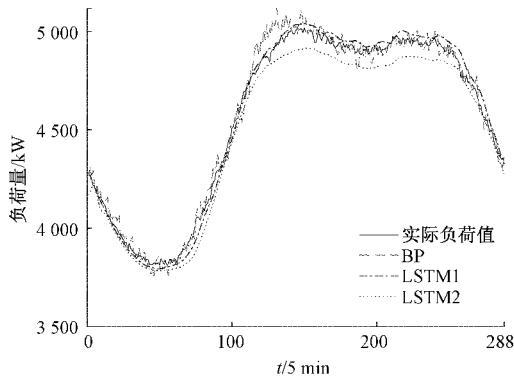


图 4 单模型预测结果

LSTM1, BP 的预测误差大于 LSTM1, 预测结果出现的波动性大于 LSTM1, 与实际曲线拟合的效果不佳, 预测精度较差, 说明 LSTM1 模型更具优势。LSTM1 与 LSTM2 的超参数设置不同, 预测结果相差较大, 由此能够看出超参数设置对 LSTM 预测精度的影响。

为了克服单一模型参数难以选取导致预测精度不足的问题, 分别利用 PSO、COA 与 ICOA 算法对 LSTM 的超参数进行寻优。为实现各优化算法的对比分析, 同时保证预测的公平性, 设置 PSO、COA、ICOA 算法的种群数目为 30, 各算法的最大迭代次数为 100。其中 PSO 算法的学习因子  $C_1$  和  $C_2$  均设置为 2, 惯性权重  $\omega$  为 0.8<sup>[25]</sup>。LSTM 的超参数  $L_1$ 、 $L_2$ 、学习率  $lr$  和迭代次数  $K$  的寻优范围分别为 [1, 200]、[1, 200]、[0.001, 0.01]、[1, 200]。在本文的实例分析中, LSTM 的 minibatchsize 设置为 256, optimizer 为 adam, 输入层神经元数为 36, 输出层神经元数为 1。各优化算法以均方差为适应度值的迭代变化过程如图 5 所示。

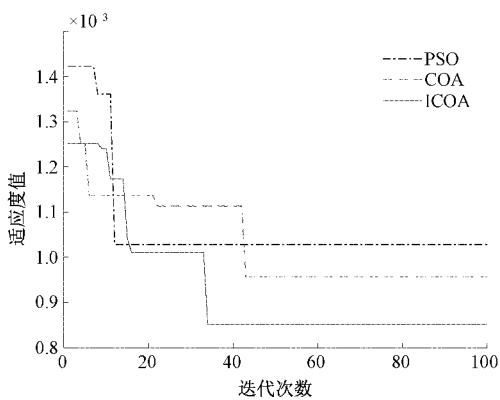


图 5 适应度变化曲线

由图 5 可以看出, 相较于 PSO 和 COA, ICOA 的寻优能力更强。在迭代寻优的过程中, PSO 在迭代初期陷入局部最优值。COA 和 ICOA 均出现陷入局部最优解的情况, 但是 ICOA 能够以较快的速度跳出局部最优值, 最终 ICOA 求解的适应度值最小, 在迭代 35 步时就达到最优适

应度值。说明 ICOA 具有更强的全局寻优能力、局部探索能力和收敛速度, 同时验证了第 2.2 节黑猩猩算法改进的有效性。基于 ICOA、COA、PSO 算法参数寻优过程如图 6~8 所示, 各算法最终寻优找到的最优 LSTM 的模型参数如表 4 所示。

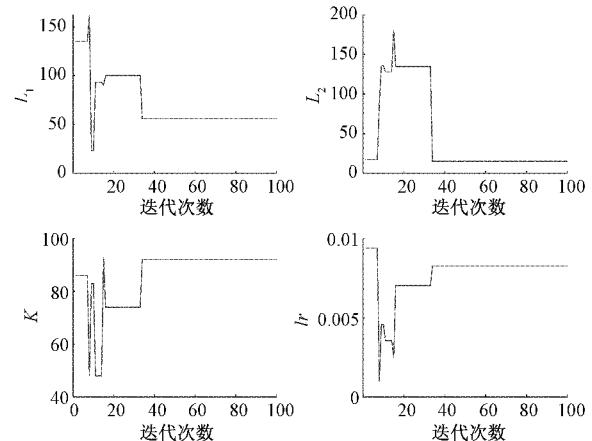
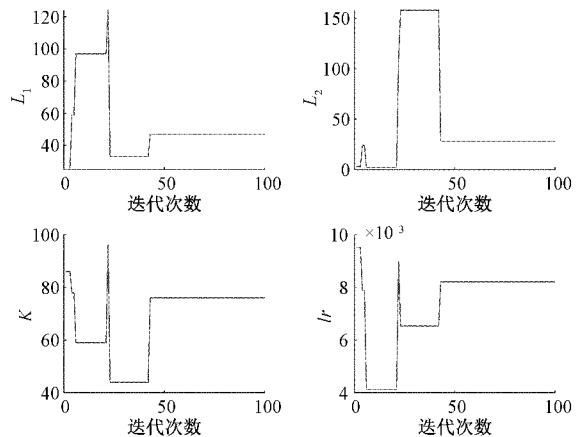
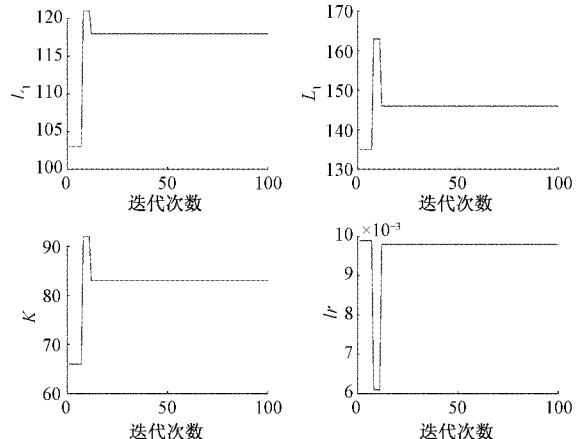
图 6 ICOA 中  $L_1$ 、 $L_2$ 、 $K$ 、 $lr$  的变化情况图 7 COA 中  $L_1$ 、 $L_2$ 、 $K$ 、 $lr$  的变化情况图 8 PSO 中  $L_1$ 、 $L_2$ 、 $K$ 、 $lr$  的变化情况

表 4 超参数寻优结果

算法	超参数			
	$L_1$	$L_2$	K	$lr$
PSO	118	146	83	0.009 8
COA	47	38	76	0.008 2
ICOA	56	15	92	0.008 3

各优化模型的预测结果如图 9 所示, 预测误差如表 5 所示。

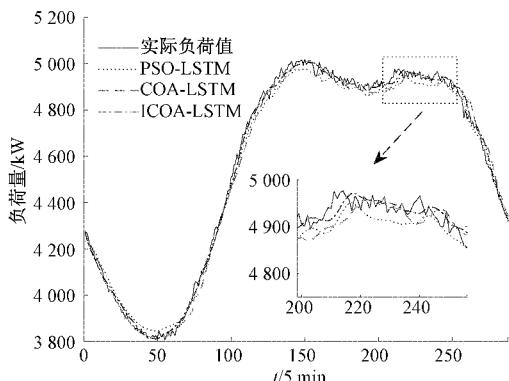


图 9 优化模型预测结果

表 5 优化模型的预测结果评价值

预测方法	MAE/kW	MAPE/%	RMSE/kW
PSO-LSTM	26.86	0.59	31.42
COA-LSTM	24.32	0.52	27.76
ICOA-LSTM	17.01	0.37	21.80

通过图 4、9 和表 3、5, 可以看出, 相较于 PSO-LSTM、COA-LSTM 和 ICOA-LSTM 模型, 单一的 LSTM 的预测效果最差, 这是由于单一的 LSTM 的超参数随机设定所造成的; 而 LSTM 的超参数经过 PSO、COA、ICOA 算法的寻优调整, 具有较高的预测精度和稳定性。ICOA-LSTM 短期负荷预测模型的 MAE、MAPE、RMSE 分别为 17.01 kW、0.37%、21.80 kW, 各项评价指标均为最优, 表明 ICOA-LSTM 的预测精度高于 LSTM、PSO-LSTM、COA-LSTM, 证明了该模型具有更高的预测精度和泛化能力。说明了利用 Circle 混沌映射策略初始化黑猩猩种群、螺旋搜索策略、动态概率切换扰动的 Levy 飞行策略和自适应  $t$  变异策略改进黑猩猩算法的有效性, 也再次印证 ICOA 的寻优能力更强, 改进的黑猩猩算法相较于基础的 PSO、COA 算法能得到更好的全局最优解, ICOA 能够构建出性能更好的基于 LSTM 的短期负荷预测模型。

## 5 结 论

针对 LSTM 模型依靠经验设定参数会使模型具有较低的泛化能力进而降低预测效果的问题, 本文提出了一种

基于 ICOA 优化 LSTM 的短期负荷预测方法。从算法的分析过程和仿真结果可以看出:

- 1) 通过在 COA 算法中引入 Circle 混沌映射策略、螺旋搜索策略、动态概率切换的 Levy 飞行和自适应  $t$  变异扰动策略, 可以使 ICOA 算法拥有更强的全局寻优能力和收敛速度, 降低了算法陷入局部最优的概率。
- 2) 利用 ICOA 算法对 LSTM 的超参数寻优, 避免了 LSTM 网络参数难以选择而导致预测精度不高的问题。相对于 PSO 和 COA, ICOA 算法的自适应能力更强, 能够搜索到更优的 LSTM 模型参数, 提高短期电力负荷的预测精度。

## 参 考 文 献

- [1] 张淑清, 要俊波, 张立国, 等. 基于改进深度稀疏自编码器及 FOA-ELM 的电力负荷预测[J]. 仪器仪表学报, 2020, 41(4): 49-57.
- [2] 宋占党, 李湘华, 王海宾, 等. 大数据环境下的电力负荷预测研究[J]. 电子测量技术, 2019, 42(12): 51-54.
- [3] 庞传军, 张波, 余建明. 基于 LSTM 循环神经网络的短期电力负荷预测[J]. 电力工程技术, 2020, 44(1): 175-194.
- [4] 夏飞, 张洁, 张浩, 等. 基于 BIC 准则和加权皮尔逊距离的居民负荷模式精细识别及预测[J]. 电子测量与仪器学报, 2020, 34(11): 33-42.
- [5] 姚栋方, 吴瀛, 罗磊, 等. 基于深度学习的短期电力负荷预测[J]. 国外电子测量技术, 2020, 39(1): 44-48.
- [6] XIA P P, XUE A H, LIAN T. Analysis and prediction regional electricity consumption based on BP neural network[J]. Journal of Quantum, 2020, 2(1): 25-32.
- [7] 马建, 腾召胜, 邱伟, 等. 基于 IGA-BP 神经网络的智能电能计量设备退化趋势研究[J]. 仪器仪表学报, 2021, 42(11): 123-131.
- [8] 黄欣, 赵锦成, 蟹璞. 基于 BP 神经网络的电站负荷预测仿真研究[J]. 国外电子测量技术, 2012, 31(10): 41-43.
- [9] 刘亚晖, 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.
- [10] 谢明磊. 基于 LSTM 网络的住宅负荷短期预测[J]. 广东电力, 2019, 32(6): 108-114.
- [11] 张淑清, 杨振宁, 张立国, 等. 基于弹性网降维及花授粉算法优化 BP 神经网络的短期电力负荷预测[J]. 仪器仪表学报, 2019, 40(7): 47-54.
- [12] 张宇帆, 艾萍, 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.
- [13] GUNDU V, SIMON S P. PSO-LSTM for short term forecast of heterogeneous time series electricity price signals [J]. Journal of Ambient Intelligence and

- Humanized Computing, 2021, 12(2): 2375-2385.
- [14] 宋思远, 朱武, 王光东, 等. 基于 IPSO-LSTM 神经网络的短期负荷预测[J]. 计算机仿真, 2021, 38(8): 92-96.
- [15] LIU C, JIN Z, GU J, et al. Short-term load forecasting using a long short-term memory network[C]. 2017 IEEE PES Innovative Smart Grid Technologies Conference Europe(ISGT-Europe), IEEE, 2017: 1-6.
- [16] KHISHE M, MOSAVI M R. Chimp optimization algorithm[J]. Expert Systems with Applications, 2020, 149: 113338.
- [17] 张达敏, 徐航, 王依柔, 等. 嵌入 Circle 映射和逐维小孔成像反向学习的鲸鱼优化算法[J]. 控制与决策, 2021, 36(5): 1173-1180.
- [18] 刘翕铭, 于水进, 杨洋. 基于改进麻雀算法的园区综合能源系统优化研究[J]. 智慧电力, 2021, 49(6): 9-16, 82.
- [19] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95(5): 51-67.
- [20] 李阳, 王维刚, 赵云涛, 等. 基于莱维飞行和随机游动策略的灰狼算法[J]. 计算机科学, 2020, 47(8): 291-296.
- [21] 韩斐斐, 刘升. 基于自适应  $t$  分布变异的缀蓝园丁鸟优化算法[J]. 微电子学与计算机, 2018, 35(8): 117-121.
- [22] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6): 1155-1164.
- [23] 韩宇, 李剑, 马慧宇, 等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法[J]. 国外电子测量技术, 2021, 40(7): 1-6.
- [24] 卞昱娇, 陈云霞, 崔宇轩. KPCA 和改进 LSTM 在滚动轴承剩余寿命预测中的应用[J]. 电子测量与仪器学报, 2021, 35(2): 109-114.
- [25] 魏腾飞, 潘庭龙. 基于改进 PSO 优化 LSTM 网络的短期电力负荷预测[J]. 系统仿真学报, 2021, 33(8): 1866-1874.

### 作者简介

- 高超, 硕士生, 主要研究方向为智能算法、负荷预测等。  
E-mail: 985905409@qq.com
- 孙谊嫡, 教授级高级工程师, 主要研究方向为电力系统优化调度、电力系统稳定控制等。  
E-mail: syq2920470@163.com
- 赵洪峰, 博士, 副教授, 主要研究方向为电力系统优化调度、电力系统稳定控制、高压绝缘材料等。  
E-mail: 115143336@qq.com
- 曹培芳, 硕士生, 主要研究方向为电力系统优化调度、储能容量优化配置等。  
E-mail: 1007199176@qq.com