

基于 ISSA-BP 的 500kV 高压线损预测模型

徐利美¹, 贺卫华¹, 李远¹, 杨射², 刘展鹏³, 续欣莹³

(1. 国网山西省电力公司, 山西太原 030021;

2. 国网山西超高压变电公司, 山西太原 030021;

3. 太原理工大学电气与动力工程学院, 山西太原 030024)

摘要:线损对评估电力系统的经济运行有着重要作用。针对高压线损与多种特征参数之间关系复杂的问题,综合考虑关口电压、关口电流及温湿度对高压线损的影响,提出一种基于改进麻雀搜索算法(ISSA)优化BP神经网络(ISSA-BP)的高压线损预测模型。首先,通过Lévy变异策略及旋转策略分别对麻雀搜索算法(SSA)的发现者及加入者的位置更新方式进行改进,并在6个基准函数上进行测试,结果表明ISSA的寻优能力得到提升。其次,通过ISSA将最优初始权值和最优初始阈值赋予BP神经网络,进而拟合出特征参数与线损率的关系。最后,以山西省某条500kV高压输电线路数据为研究对象,对比分析BP、GWO-BP、WOA-BP、SSA-BP与ISSA-BP这五种预测模型的预测效果,结果表明ISSA-BP模型的预测值最接近实际值,其RMSE、MAPE、MAE和R2分别为4.29%、3.67%、3.57%和99.01%,均为各种预测模型中最佳。相较于SSA-BP,ISSA-BP的RMSE下降了33.4%,MAPE下降了36.7%,MAE下降了37.1%,R2提高了1.24%,表明ISSA-BP模型能对高压线损进行准确预测。

关键词:500 kV 高压;线损预测;BP神经网络;麻雀搜索算法;Lévy变异策略;旋转策略;基准函数

中图分类号:TP183;TM744

文献标识码:A

文章编号:1673-629X(2023)05-0214-07

doi:10.3969/j.issn.1673-629X.2023.05.032

Prediction Model of 500kV High Voltage Line Loss Based on ISSA-BP

XU Li-mei¹, HE Wei-hua¹, LI Yuan¹, YANG She², LIU Zhan-peng³, XU Xin-ying³

(1. State Grid Shanxi Electric Power Company, Taiyuan 030021, China;

2. State Grid Shanxi Extra High Voltage Substation Company, Taiyuan 030021, China;

3. School of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: Line loss plays an important role in evaluating the economic operation of a power system. Aiming at the complex relationship between high voltage line loss and various characteristic parameters, considering the influence of gate voltage, gate current and temperature and humidity on high voltage line loss, we propose a high voltage line loss prediction model based on improved sparrow search algorithm (ISSA) optimized BP neural network (ISSA-BP). Firstly, the position update methods of the discoverers and joiners of the sparrow search algorithm (SSA) are improved through the Lévy mutation strategy and the rotation strategy, respectively, and tested on six benchmark functions. The results show that the optimization ability of ISSA has been improved. Secondly, the optimal initial weights and optimal initial thresholds are given to the BP neural network through ISSA, and then the relationship between the characteristic parameters and the line loss rate is fitted. Finally, taking the data of a 500kV high voltage transmission line in Shanxi Province as the research object, the prediction effects of five prediction models of BP, GWO-BP, WOA-BP, SSA-BP and ISSA-BP are compared and analyzed. The predicted value is the closest to the actual value, and its RMSE, MAPE, MAE and R2 are 4.29%, 3.67%, 3.57% and 99.01%, respectively, which are the best among various prediction models. Compared with SSA-BP, the RMSE of ISSA-BP decreased by 33.4%, MAPE decreased by 36.7%, MAE decreased by 37.1%, and R2 increased by 1.24%. It is showed that ISSA-BP model can accurately predict high voltage line loss.

Key words: 500 kV high voltage; line loss prediction; BP neural network; sparrow search algorithm; Lévy mutation strategy; rotation strategy; benchmark function

0 引言

全球能源危机不断加剧,降损是改善电力资源浪费的有效途径,此过程需要对线损进行准确、可靠的预测^[1]。电能通过输电、变电等设备时,由于设备之间存在阻抗,就会产生电能损耗,这个损耗称为线损^[2]。线损率是指向电网中供应单位电能产生的电能损耗。线损率作为电力系统中的重要指标,在很大程度上可以反映出电网运行的经济性。

高压输电线的线损主要包括电阻损耗和电晕损耗。电阻损耗由于电流流过输电线时发热而产生,其主要与输电线的材质及电流大小有关。电晕损耗主要与气象条件有关,由于导线表面的空气被击穿,电能转换成光和热等其他形式的能量而产生。降雨时,导线表面最大场强增加,电晕损耗也会明显增大^[3]。

山西电网依靠其丰富的煤炭资源、适中的地理位置,在西电东送、南北互供、全国联网的总体布局中占据着重要的地位^[4]。为了对山西省北部某段 500 kV 电压等级输电线的线损情况进行分析,准确预测此段线路的线损率,有必要对其进行专门研究。

现如今,理论线损的计算方法应用已经相当广泛,有等值电阻法^[5]、均方根电流法^[6]等。但上述方法均无法考虑气象因素对线损的影响。近年来,人工智能技术得到了快速的发展,神经网络算法在很多领域都得到了应用,这也为线损预测提供了新的方法。文献[7]采用 BP 神经网络对线损进行预测。但 BP 神经网络的初始权值和阈值是随机确定的,导致预测精度受到影响。文献[8]采用改进的 BP 神经网络对线损进行预测,此方法可以对低压配网的线损进行很好的预测,但无法对高压线损进行准确预测。文献[9]采用了优化的反向传播神经网络来对线损进行预测。该方法与传统的人工神经网络方法相比,具有了更高的精度和收敛速度,但有可能出现过拟合的情况。文献[10]采用 LM 算法优化 BP 神经网络的方法对线损进行预测。优化后的 BP 神经网络相较于标准 BP 神经网络其收敛速度明显提升,但有可能出现陷入局部极小值的情况。文献[11]改进了 BP 算法中的梯度下降法,虽然 BP 神经网络的计算性能得到了提高,但没有研究输入层如何对电气参数进行确定。文献[12]采用遗传算法优化 BP 神经网络的方法对线损进行预测,但遗传算法容易早熟收敛,导致网络在训练过程中会出现陷入局部最优解的情况。

BP 神经网络结构简单,使用方便,但其对初始权值及初始阈值的选择较为敏感,不同的初始权值和阈值会使网络收敛于不同的局部最优值。可利用智能优化算法优化 BP 神经网络的初始参数。麻雀搜索算法(Sparrow Search Algorithm, SSA)^[13]于 2020 年被提

出,SSA 收敛速度快、收敛精度高,但容易早熟收敛,对其改进可以提高 SSA 的寻优能力。因此,本文提出了一种基于改进麻雀搜索算法(Improved Sparrow Search Algorithm, ISSA)优化 BP 神经网络(ISSA-BP)的高压线损预测模型,并以实际高压输电线线损样本数据为例进行试验。结果表明,利用 ISSA-BP 模型进行线损预测,可以提高模型的预测精度。

1 相关工作

1.1 BP 神经网络

BP 神经网络具有较强的非线性映射及自适应能力,在预测领域得到了广泛的应用。BP 神经网络由输入层、隐含层和输出层构成,通常具有 3 层及以上的结构。3 层 BP 神经网络结构如图 1 所示。




图 1 3 层 BP 神经网络结构

图 1 中, $I_i (i=1, 2, \dots, n)$ 表示网络的输入; $O_j (j=1, 2, \dots, m)$ 表示网络的输出。BP 神经网络的学习过程包括信号的正向传播和误差的反向传播两个阶段。在第一阶段,网络输入信号从输入层传递到隐含层,经过隐含层激活函数的激活操作后再传递到输出层。经过隐含层激活函数作用后,可以将隐含层的输出控制在 0~1 的范围内,接着再传递到输出层。在第二阶段,网络根据预测值与标签值的误差对比结果进行反向传播,通过调整各神经元之间的权值和阈值,使得整个网络向误差减小的方向不断更正^[14]。

1.2 麻雀搜索算法

在一个种群中,有发现者、加入者和警戒者三种类型的麻雀,每一只麻雀都对应着一组可能的初始权值及初始阈值^[15]。

SSA 在每次迭代时,发现者位置更新表示为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot G}\right) & \text{if } R_2 < ST \\ X_{i,j}^t + Q \cdot L & \text{if } R_2 \geq ST \end{cases} \quad (1)$$

其中, $X_{i,j}^t$ 表示在第 t 次迭代时,第 i 只麻雀在第 j 维空间的位置; α 为(0,1]之间的随机数; G 为最大的迭代次数; Q 为服从标准正态分布的随机数; L 为每个元素都为 1 的 $1 \times d$ 矩阵。 $R_2 \in (0, 1]$, 为预警值; $ST \in$

[0.5, 1], 为安全值。当 $R_2 < ST$ 时, 表明当前觅食环境比较安全, 发现者可以更广泛地进行搜索; 当 $R_2 \geq ST$ 时, 表示当前觅食环境不再安全, 发现者发出危险信号, 麻雀迅速飞向安全区。

SSA 在每次迭代时, 加入者位置更新表示为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right) & \text{if } i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L} & \text{otherwise} \end{cases} \quad (2)$$

其中, X_{worst}^t 表示种群第 t 次迭代时麻雀在全局的最劣位置; X_p^{t+1} 表示种群在第 $t+1$ 次迭代时麻雀在全局的最优位置; \mathbf{A} 为 $1 \times d$ 矩阵, 其元素随机分配为 1 或 -1, 且 $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)$ 。当 $i > n/2$ 时, 表示第 i 个加入者没有获取到食物, 需要前往别的地方寻找食物。当 $i \leq n/2$ 时, 第 i 个加入者会在当前全局最优位置附近随机寻找食物。

SSA 在每次迭代时, 警戒者位置更新表示为:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t| & \text{if } f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon}\right) & \text{if } f_i \leq f_g \end{cases} \quad (3)$$

其中, X_{best}^t 为当前的全局最优位置; β 为控制步长的参数, 其值服从均值为 0 方差为 1 的正态分布; K 也是控制步长的参数, 其值为 $[-1, 1]$ 的随机数; ε 是为了避免分母为零而取的最小常数; f_i 表示第 i 只麻雀的适应度值; f_g 和 f_w 分别表示全局最优位置和全局最劣位置的适应度值; $f_i > f_g$ 时, 表示警戒者在种群边缘, 它们处于危险的处境, 但全局最优位置 X_{best}^t 及其周围安全; $f_i \leq f_g$ 时, 表示警戒者已经位于种群的中心位置, 麻雀群中有捕食者, 警戒者随机向其他麻雀靠拢, 以此来减少它们被捕食的风险。

2 改进的麻雀搜索算法

2.1 麻雀搜索算法的改进策略

传统 SSA 具有容易陷入局部最优及早熟收敛的缺点。该文将 Lévy 变异引入发现者机制, 将旋转策略引入加入者机制, 以此增强 SSA 的寻优能力。

(1) Lévy 变异策略。

Lévy 分布^[16]是非负随机变量的连续概率分布, 其数学表征为:

$$f(x; \mu, c) = \sqrt{\frac{c}{2\pi}} \frac{e^{-\frac{c}{2(x-\mu)}}}{(x-\mu)^{3/2}} \quad (4)$$

其中, μ 为位置参数, c 为标度参数。相较于 Gaussian 分布与 Tent 分布, Lévy 分布产生的随机数其随机性与分布均匀性均为最强, 因此 Lévy 分布能对搜索空间进

行更好、更高效的搜索。

通常迭代次数过半时进入迭代后期。设置迭代次数为 100, 经实验得出, 迭代次数为 65 ~ 75 时效果最好。因此, 该文设置迭代次数为 65 ~ 75 时引入 Lévy 变异策略。改进后的发现者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot G}\right) & \text{if } R_2 < ST \\ X_{i,j}^t + Q \cdot \mathbf{L} + \text{Lévyrand} \cdot \mathbf{L} & \text{if } R_2 \geq ST \end{cases} \quad (5)$$

(2) 旋转策略。

受状态转移算法 (State Transition Algorithm, STA)^[17] 中旋转策略启发, 将旋转策略引入加入者机制中, 扩大加入者搜索范围, 避免算法早熟收敛。改进后的加入者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right) & \text{if } i > n/2 \\ X_p^{t+1} + \varepsilon_\alpha \cdot \frac{1}{n \cdot \|X_p^{t+1}\|_2} R_r X_p^{t+1} & \text{otherwise} \end{cases} \quad (6)$$

其中, ε_α 称为旋转因子, 旋转策略的引入可以使生成的候选解在半径为 ε_α 的超球里。其数学原理如式 (7) 所示:

$$\begin{aligned} \|X_{i,j}^{t+1} - X_p^{t+1}\|_2 &= \left\| \varepsilon_\alpha \cdot \frac{1}{n \cdot \|X_p^{t+1}\|_2} R_r X_p^{t+1} \right\|_2 = \\ &= \frac{\varepsilon_\alpha}{n \cdot \|X_p^{t+1}\|_2} \|R_r X_p^{t+1}\|_2 \leq \\ &= \frac{\varepsilon_\alpha}{n \cdot \|X_p^{t+1}\|_2} \|R_r\|_\infty \|X_p^{t+1}\|_2 \leq \varepsilon_\alpha \end{aligned} \quad (7)$$

在式 (6) 中, 当 ε_α 取值较大时, 搜索空间变大, 算法全局探索能力增强; 反之, 当 ε_α 取值较小时, 算法局部开发能力增强。为避免算法出现早熟收敛现象, 该文对参数 ε_α 进行重新设计, 重新设计后的 ε_α 表示为:

$$\varepsilon_\alpha = |X_{i,j}^{t+1} - X_p^{t+1}| \cdot \mathbf{B}^+ \quad (8)$$

其中, $\mathbf{B}^+ = \mathbf{B}^T(\mathbf{B}\mathbf{B}^T)^{-1}$, \mathbf{B} 为 $1 \times d$ 阶矩阵。在迭代初期, 向量 $X_{i,j}^{t+1}$ 与 X_p^{t+1} 之间的曼哈顿距离较大, 导致 ε_α 较大, 搜索空间变大, 算法全局探索能力增强。同理, 随着迭代次数的增加, ε_α 逐渐减小, 算法局部开发能力增强。因此, 上述方式能较好地平衡算法的全局探索能力和局部开发能力。

2.2 改进麻雀搜索算法的性能测试

为验证 ISSA 算法的有效性, 选取了 6 个基准函数对 ISSA 进行测试。其中, $F_1 \sim F_3$ 为单峰基准函数, $F_4 \sim F_6$ 为多峰基准函数。基准函数表达式如下:

$$F_1(x) = \sum_{i=1}^n x_i^2 \quad (9)$$

$$F_2(x) = \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \quad (10)$$

$$F_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2 \quad (11)$$

$$F_4(x) = \sum_{i=1}^n -x_i \sin(\sqrt{|x_i|}) \quad (12)$$

$$F_5(x) = \frac{\pi}{n} \{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \} + \sum_{i=1}^n u(x_i, 10, 100, 4)$$

$$y_i = 1 + \frac{x_i + 1}{4}$$

$$u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a \leq x_i \leq a \\ k(-x_i - a)^m & x_i < -a \end{cases} \quad (13)$$

$$F_6(x) = 0.1 \{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \} + \sum_{i=1}^n u(x_i, 5, 100, 4) \quad (14)$$

基准函数具体信息如表 1 所示。

表 1 基准函数具体信息

函数	维度	搜索区间	最小值
F_1	30	[-100,100]	0
F_2	30	[-10,10]	0
F_3	30	[-100,100]	0
F_4	30	[-500,500]	-12 569.5
F_5	30	[-50,50]	0
F_6	30	[-50,50]	0

为了测试 ISSA 的寻优能力是否得到提升,将灰狼优化算法 (Grey Wolf Optimizer, GWO)^[18]、鲸鱼优化算法 (Whale Optimization Algorithm, WOA)^[19]、SSA 及 ISSA 在上述 6 个基准函数上进行测试。其中,WOA 中的对数螺旋形状系数 $b = 1$,GWO、WOA、SSA 与 ISSA 种群数量均设定为 30,最大迭代次数均设定为 1 000,实验均独立重复运行 30 次,取 30 次实验结果的平均值及标准差。测试结果如表 2 所示。

表 2 基准函数测试结果

函数	指标	GWO	WOA	SSA	ISSA
F_1	\bar{x}	8.81e-59	4.28e-72	6.54e-81	1.19e-130
	s	2.44e-58	2.28e-71	3.58e-80	6.50e-130
F_2	\bar{x}	1.02e-34	6.80e-35	4.78e-36	1.61e-68
	s	9.45e-35	2.04e-34	2.62e-35	7.55e-68

续表 2

函数	指标	GWO	WOA	SSA	ISSA
F_3	\bar{x}	5.53e-14	1.95e-43	1.37e-64	3.87e-80
	s	2.93e-13	1.18e-42	7.49e-64	2.12e-89
F_4	\bar{x}	-6.10e+03	-6.92e+03	-8.20e+03	-9.36e+03
	s	8.13e+03	1.70e+03	7.11e+02	2.35e+02
F_5	\bar{x}	5.30e-02	6.47e-03	6.10e-12	4.17e-17
	s	9.30e-02	8.70e-03	1.30e-11	1.13e-16
F_6	\bar{x}	0.52	0.23	1.88e-11	1.37e-15
	s	0.23	0.15	4.07e-11	2.21e-15

其中, \bar{x} 表示平均值, s 表示标准差。由表 2 可得,在单峰基准函数 $F_1 \sim F_3$ 及多峰基准函数 $F_4 \sim F_6$ 中,相较于 GWO、WOA 和 SSA,ISSA 寻找的最小值均更接近基准函数的理论最小值,表明 ISSA 同时具有较强的全局搜索能力和局部搜索能力,验证了对麻雀搜索算法改进的有效性。

3 ISSA-BP 高压线损预测模型的建立

BP 神经网络的初始权值和阈值为 0~1 之间产生的随机数,每次训练都会得到不同的结果,多次训练后才会选择拟合较好的一个网络^[12]。该文采用 ISSA 对 BP 神经网络的初始权值和阈值进行优化。以某条实际高压输电线路为研究对象,在综合考虑了此输电线路相关数据获取的难易程度以及线路运行实际情况之后,决定选取关口电压、关口电流、温度和相对湿度这四个特征参数,综合研究上述特征参数对高压线损的影响。

ISSA 优化 BP 神经网络的具体流程如下:

Step1 数据归一化。由于各维度输入数据差异性较大,需对输入数据做归一化操作,经归一化处理后的样本数据位于[-1,1]之间,计算公式如下:

$$x'_i = 2 \cdot \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (15)$$

其中, x_i 表示第 i 个输入样本值, x_{\max} 与 x_{\min} 分别表示输入样本的最大值与最小值, x'_i 表示经过归一化处理后的第 i 个样本值;

Step2 确定 BP 神经网络的结构,并初始化网络参数。由于模型输入为关口电压、关口电流、温度和相对湿度,输出为线损值,因此 BP 神经网络的输入层节点数为 4,输出层节点数为 1。隐含层节点数过大或过小都会影响网络的预测精度,通过反复测试,最终确定隐含层节点数为 16;

Step3 初始化 ISSA。设置 ISSA 搜索维度、最大迭代次数、麻雀种群规模、发现者数量、加入者数量、警戒者数量及预警值;

Step4 计算每个麻雀个体的适应度并排序。适应度表示 ISSA 中种群个体的优劣情况,该文采用均方误差 (Mean Square Error, MSE) 作为 ISSA 的适应度函数, MSE 的表达式为:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2 \quad (16)$$

其中, Y_i 与 Y_i^* 分别表示第 i 个数据的真实值和预测值, ISSA 向着适应度减小的方向进行;

Step5 更新麻雀位置。按式(5)更新麻雀种群中发现者位置,按式(6)更新种群中加入者位置,按式(3)更新种群中警戒者位置,并计算更新后麻雀的适应度值;

Step6 判断模型是否满足结束条件。当算法的循环次数达到最大迭代次数时,算法终止。否则,算法返回到上一步,继续更新麻雀位置;

Step7 输出适应度最小的麻雀位置。当模型满足结束条件时,模型输出适应度最小的麻雀位置,即输出 BP 神经网络的最佳初始权值和最佳初始阈值;

Step8 高压线损预测。将 ISSA 寻找的最佳初始权值和阈值赋予 BP 神经网络,网络通过误差反向传播的方式不断更新权值和阈值,当达到最大迭代次数时,输出高压线损预测值。

ISSA-BP 算法流程如图 2 所示。

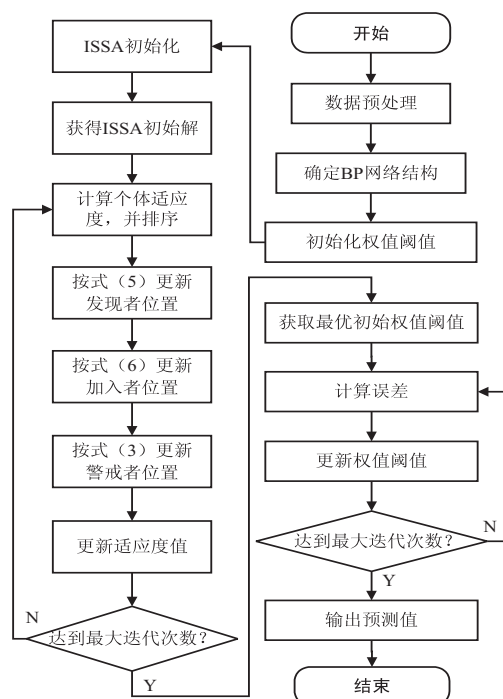


图 2 ISSA-BP 算法流程

4 实验仿真

4.1 实验环境及参数设置

实验仿真时计算机主要硬件配置如下:CPU 为 Intel® Core™ i5-7200U, 基准频率为 2.50 GHz; 仿真

软件为 MATLAB2018b。

BP 神经网络的输入层、隐含层和输出层节点数分别为 4、16 和 1, 因此共有 $4 \times 16 + 16 \times 1 = 80$ 个权值, $16 + 1 = 17$ 个阈值。设置 ISSA 搜索维度为 $80 + 17 = 97$, 麻雀数量为 20, 最大迭代次数为 100, 发现者占比 0.2, 加入者占比 0.7, 警戒者占比 0.1, 预警值为 0.8。按照图 2 所示算法流程训练模型。

4.2 实验数据及预处理

为了验证 ISSA-BP 模型的有效性, 选取山西省某条高压输电线路在 2021 年 6~8 月份的关口电压、关口电流、温度和相对湿度数据, 数据采样周期为 15 分钟, 对数据进行分析并剔除异常值后, 得到 8 000 组数据。随机选择其中的 7 900 组数据作为训练集, 其余 100 组数据作为测试集。

4.3 评价指标

该文选取均方根误差 (Root Mean Square Error, RMSE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)、平均绝对误差 (Mean Absolute Error, MAE) 和决定系数 (Coefficient of Determination, R²) 为性能评价指标, RMSE、MAPE、MAE 和 R² 的表达式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2} \quad (17)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - Y_i^*}{Y_i} \right| \times 100\% \quad (18)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y_i^*| \quad (19)$$

$$R_2 = 1 - \frac{\sum_{i=1}^N (Y_i - Y_i^*)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (20)$$

其中, Y_i 与 Y_i^* 分别表示第 i 个数据的真实值和预测值, \bar{Y} 表示数据的平均值。RMSE、MAPE 与 MAE 越小, 预测精度越高; R_2 越接近 1, 预测精度越高。

4.4 结果分析

BP、GWO-BP、WOA-BP、SSA-BP 与 ISSA-BP 迭代次数均设置为 100, 使用上述模型对测试集中的 100 条样本数据进行预测。五种模型的预测结果及误差 (真实值-预测值) 分别如图 3~图 7 所示, 预测结果的局部放大如图 8 所示。

由图 3~图 8 可以看出: 以上五种预测模型中, BP 神经网络预测模型效果最差, 当线损发生剧烈波动时, 其预测值与实际值偏差较大, 不能很好地反映线损的真实情况。GWO-BP、WOA-BP、SSA-BP 与 ISSA-BP 模型的预测精度相较于 BP 神经网络均有所提高。ISSA-BP 模型的预测效果最好, 即使线损出现波动较大的情

况,其误差也能保持较小的值,预测曲线可以与实际曲线很好地拟合。




图 3 BP 网络预测结果




图 4 GWO-BP 预测结果




图 5 WOA-BP 预测结果




图 6 SSA-BP 预测结果




图 7 ISSA-BP 预测结果




图 8 预测结果局部放大

使用上述评价指标对五种模型的预测效果进行评价,得到的误差统计如表 3 所示。

表 3 误差统计 %

预测模型	RMSE	MAPE	MAE	R_2
BP	9.06	8.20	7.98	95.59
GWO-BP	8.38	7.10	7.25	96.22
WOA-BP	6.97	5.90	6.05	97.39
SSA-BP	6.44	5.79	5.68	97.77
ISSA-BP	4.29	3.67	3.57	99.01

从表 3 可得,使用以上五种模型进行线损预测时, BP 网络预测精度最低,其 RMSE、MAPE、MAE 与 R_2 分别为 9.06%、8.20%、7.98% 与 95.59%,均为预测模型中最差。BP 网络经过 GWO、WOA、SSA 与 ISSA 优化后,预测误差都有明显降低。其中,ISSA-BP 预测效果最佳,其 RMSE、MAPE、MAE 与 R_2 分别为 4.29%、3.67%、3.57% 与 99.01%,均为预测模型中最优。相较于 BP 网络,ISSA-BP 的 RMSE 下降了 52.6%,MAPE 下降了 55.2%,MAE 下降了 55.3%, R_2 提高了 2.18%。相较于 SSA-BP 网络,ISSA-BP 的 RMSE 下降了 33.4%,MAPE 下降了 36.7%,MAE 下降了 37.1%, R_2 提高了 1.24%。结果表明,通过 ISSA 优化 BP 神经网络的初始权值和阈值,可以有效提高高压线损的预测精度。

5 结束语

为了更准确地对 500 kV 高压线损进行预测,综合考虑温湿度等特征参数的影响,提出了一种基于 ISSA-BP 的高压线损预测模型。传统 SSA 在迭代后期容易陷入局部最优值,导致其优化 BP 神经网络的效率降低,该文对 SSA 中发现者及加入者位置更新方式进行改进,并在 6 个基准函数对 ISSA 进行性能测试,结果表明,ISSA 的寻优能力有了很大提升。为验证将 ISSA-BP 模型用于提高线损预测精度的有效性,以实际高压输电线路为研究对象进行试验,结果表明,通过 ISSA 优化 BP 神经网络,能在很大程度上提高模型的预测精度。

参考文献:

- [1] 陈广宇,张磊,赵磊,等.基于改进神经网络的电网线损率预测模型分析[J].自动化技术与应用,2022,41(5):130-133.
- [2] 杨建华,肖达强,张伟,等.基于改进 PSO 优化的 RBF 神经网络的特高压线损预测[J].广东电力,2020,33(9):85-91.
- [3] 王江储.基于数据知识融合的输电线路线损计算与线损异常分析研究[D].广州:华南理工大学,2020.
- [4] 李国宝,刘新元,杨尉薇.山西电网运行安全风险[J].山西电力,2019(2):6-9.
- [5] 江木,孙云超,刘巨.10kV 配电网理论线损计算方法及应用对比[J].供用电,2019,36(11):78-83.
- [6] 李石东.10kV 架空线线损波动计算分析[D].广州:华南理工大学,2019.
- [7] 李植鹏,侯惠勇,蒋嗣凡,等.基于人工神经网络的线损计算及窃电分析[J].南方电网技术,2019,13(2):7-12.
- [8] 张毅,陈炜多,陈思瀚,等.基于改进 BP 神经网络的宁德地区配电网线损预测方法[J].电气技术与经济,2021(5):6-9.
- [9] 李亚,刘丽平,李柏青,等.基于改进 K-Means 聚类
- BP 神经网络的台区线损率计算方法[J].中国电机工程学报,2016,36(17):4543-4551.
- [10] LIU Liping, LI Baiqing, LI Ya, et al. Calculation of line loss in low-voltage transformer district based on BP network model optimized by LM algorithm [C]//IEEE electrical power and energy conference (EPEC). Ottawa: IEEE, 2016: 1-6.
- [11] 张勤,马玮,付锦,等.中压配电网规划态线损计算方法[J].电气技术,2018,19(2):42-45.
- [12] 胡伟楠,王剑飞,何志满,等.基于遗传算法优化神经网络的智能配电网线损计算研究[J].物联网技术,2020,10(1):40-43.
- [13] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering An Open Access Journal, 2020, 8(1):22-34.
- [14] 尚福华,王玮卿,曹茂俊.基于改进 BP 神经网络的页岩地应力预测模型[J].计算机技术与发展,2021,31(7):164-170.
- [15] 崔乃丹.基于粒子群优化算法与 BP 神经网络的高铁客运量预测算法[J].自动化技术与应用,2022,41(4):148-150.
- [16] JIA Heming, LANG Chunbo. Salp swarm algorithm with crossover scheme and Lévy flight for global optimization [J]. Journal of Intelligent and Fuzzy Systems, 2021, 40(12):1-12.
- [17] BI Jian, ZHOU Guo, ZHOU Yongquan, et al. Artificial electric field algorithm with greedy state transition strategy for spherical multiple traveling salesmen problem [J]. International Journal of Computational Intelligence Systems, 2022, 15(1):1-24.
- [18] 逯苗.灰狼优化算法的改进及应用[D].南宁:广西民族大学,2021.
- [19] 李安东,刘升.混合策略改进鲸鱼优化算法[J].计算机应用研究,2022,39(5):1415-1421.