

文章编号: 2095-2163(2021)10-0107-07

中图分类号: TM732

文献标志码: A

基于 WOA 优化 LSTM 神经网络的配电网可靠性评估

万俊杰, 单鸿涛

(上海工程技术大学 电子电气工程学院, 上海 201620)

摘要: 为了提高配电网可靠性评估的精度, 提出了一种基于鲸鱼优化算法(WOA)优化 LSTM 的配电网可靠性评估方法。首先对配电网可靠性数据进行预处理, 然后通过利用 WOA 对 LSTM 模型的隐藏层神经元数量、学习率和迭代次数进行寻优得到最优参数, 建立 WOA-LSTM 配电网可靠性评估模型, 最终得到模型的输出。同时与传统的 Monte Carlo 法、深度信念网络(DBN)模型和 LSTM 模型作对比研究。仿真结果表明, 采用 WOA 优化的 LSTM 模型在配电网可靠性评估方面明显要优于其他模型。

关键词: 配电网可靠性评估; 鲸鱼算法; LSTM; 参数优化

Reliability evaluation of distribution network based on WOA algorithm optimized LSTM neural network

WAN Junjie, SHAN Hongtao

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] In order to improve the accuracy of the reliability evaluation of the distribution network, a distribution network reliability evaluation method based on the Whale Optimization Algorithm (WOA) optimized LSTM is proposed. Firstly, the distribution network reliability data is preprocessed, then the optimal parameters are obtained by using WOA to optimize the number of hidden layer neurons, the learning rate and the number of iterations of the LSTM model, and the WOA-LSTM distribution network reliability evaluation model is established, finally gets the output of the model. At the same time, the traditional Monte Carlo method, the deep belief network (DBN) model and the LSTM model are used as comparative research. The simulation results show that the LSTM model optimized by WOA is significantly better than other models in the reliability evaluation of the distribution network.

[Key words] distribution network reliability evaluation; whale algorithm; LSTM; parameter optimization

0 引言

配电网是电力系统的重要组成部分, 其广泛的范围和复杂的结构对可靠性有着重要的影响。因此, 对配电网可靠性进行准确分析即已成为目前的研究热点^[1]。

随着工业技术的快速发展, 欧美的一些国家开始将配电网可靠性评估列入研究范围。1964年, 作为一种统计模型, Desineo 等人首次将马尔可夫模型应用到配电网可靠性评估中, 此后 Billinton 等人^[2]对该模型进行深入研究, 对马尔可夫模型中转移矩阵组成的线性方程进行求解, 最终计算出了系统的平均故障时间以及平均故障修复时间。上世纪六十年代, 加拿大建立了全球报告系统, 该系统明确指出要对配电网可靠性的历史数据进行分析, 对于不同等级的网架结构需要制定各自的标准^[3]。日本对

配电网可靠性的研究有其独特之处, 日本对于配电网可靠性各个指标的计算是全国一致的, 并将“裕度”这一概念应用于配电网可靠性评估中, 以此进行相关研究^[4]。国内的配电网可靠性研究起步于二十世纪七十年代, 1985年, 为进行配电网可靠性研究又建立了电力系统可靠性管理中心, 并在此基础上开展配电网可靠性研究工作^[5]。继而, 在1989年国内又颁布了《供电系统用户供电可靠性统计办法》, 自该方法执行以来, 配电网可靠性的相关工作就得到了迅速发展。

目前常用的配电网可靠性分析方法有3种, 分别是: 模拟法、解析法和人工智能方法。其中, 蒙特卡洛法是模拟法中最常见的一种方法。蒙特卡洛法的计算精度和抽样次数直接相关, 只是其计算量大以及计算时间长的特点很难满足在线分析的需求^[6]。解析法一般包括状态枚举法^[7]、故障模式影

作者简介: 万俊杰(1996-), 男, 硕士研究生, 主要研究方向: 配电网可靠性评估; 单鸿涛(1971-), 女, 博士, 副教授, 主要研究方向: 逆变器数字控制技术以及并联技术。

通讯作者: 万俊杰 Email: 2352725423@qq.com

收稿日期: 2021-03-23

响分析法^[8]及最小路法^[9]等。但是随着网络结构复杂性的增加,使其可靠性分析的难度水平也随之提升,导致计算量大,速度慢的问题。神经网络算法基于历史样本数据进行分析,其自适应能力强,训练好后可靠性分析时间及计算量有所减少,但计算精度有待提高^[10]。人工神经网络方法的理论主要包括前向递推和反向调节。文献[11]结合了传统的蒙特卡洛法和人工智能算法,用于配电网可靠性指标的计算,取得了较好的效果。文献[12]找出影响配电网可靠性的因素,将这些因素作为模型的输入,利用处理线性能力较强的BP神经网络来研发配电网可靠性评估模型。文献[13]采用了泛化能力较强的径向基(RBF)神经网络,将配电网可靠性原始数据分为训练集和测试集,对原始数据进行拟合取得了良好的效果。文献[14]提出一种粒子群优化算法(PSO)优化最小二乘支持向量机(LSSVM)的配网供电可靠性评估方法。通过选择影响城市供电可靠性的主要因素作为模型的输入,利用粒子群优化算法(PSO)较强的参数寻优性能对最小二乘支持向量机(LSSVM)的模型参数进行处理得到最优模型,并将该模型应用于实际电网中,证明该方法是可行有效的。文献[15]提出了一种基于改进的粒子群算法(PSO)优化广义回归神经网络(GRNN)的配电网可靠性预测模型。先是在基本粒子群算法中引入惯性权重有效地提高了算法的全局和局部搜索能力,然后使用改进的粒子群算法优化广义回归神经网络的模型参数光滑因子,最后通过实例分析该模型具有良好的预测效果。

深度神经网络模型具有层层堆叠的隐含层结构特征,每层抽取不同的数据特征作为下一层的输入。通过输入输出之间的非线性关系,低级特征可以与高级抽象表示相结合。目前,LSTM已成功解决了许多问题,如负荷预测、股价预测、文本分类等。

1 鲸鱼优化算法

鲸鱼优化算法(Whale Optimization Algorithm, WOA)是近些年提出的一种新型的群智能算法。原理简单,设置的参数相对较少,拥有很强的全局搜索能力。鲸鱼优化算法优化特定的问题时,类似鲸鱼捕食的行为。当猎物出现时,鲸鱼首先会选择潜入到猎物的下方,然后通过旋转的方式向上,对猎物进行攻击时则在其周围形成气泡呈螺旋状。鲸鱼捕食的过程主要分为3个过程,分别为环绕猎物、形成螺旋气泡攻击猎物和搜索过程。对此拟做研究阐释

如下。

在捕食的过程中,猎物的位置即为最佳位置,鲸鱼则通过收缩环绕和螺旋来改变自身的位置。鲸鱼收缩环绕的过程如下:

$$D = |C \cdot X^*(t) - X(t)| \quad (1)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (2)$$

其中, t 为当前的迭代次数; X 为位置向量; X^* 为最优位置向量; D 为衡量位置的参数; A 和 C 分别表示2个控制参数向量,通过下式计算可得:

$$A = 2a \cdot r - a \quad (3)$$

$$C = 2 \cdot r \quad (4)$$

其中, r 是0到1之间的任意向量, a 的值与 t 和 $t_{MaxIter}$ 有关,并随着迭代次数的增加而不断减少,这就是收缩环绕行为的体现。此时涉及的数学公式可写为:

$$a = 2 - 2 \cdot \frac{t}{t_{MaxIter}} \quad (5)$$

其中, $t_{MaxIter}$ 表示最大迭代次数。

鲸鱼通过螺旋方式更新位置的公式如下:

$$D' = |X^*(t) - X(t)| \quad (6)$$

$$x(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) \quad (7)$$

其中, D' 表示2个位置之间的距离; l 是任意数,取值在-1到-2之间; b 为常数,正常情况下取自然数1,具体计算公式为:

$$b = -1 - \frac{t}{t_{MaxIter}} \quad (8)$$

由于鲸鱼在捕食的过程中同时进行收缩环绕和螺旋更新位置,则这两种行为进行的概率皆取1/2,即:

$$X(t+1) = \begin{cases} X^*(t) - A \cdot D & p < 0.5 \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) & p \geq 0.5 \end{cases} \quad (9)$$

其中, $p \in [0,1]$ 。

鲸鱼在捕食的过程中,为到达全局最优位置,会在所处的区域中不断搜索以更新自身的位置,该过程中需用到的数学公式为:

$$D = |C \cdot X_{rand} - X| \quad (10)$$

$$X(t+1) = X_{rand} - A \cdot D \quad (11)$$

其中, X_{rand} 为位置向量,从当前一代中随机选取。

鲸鱼更新位置的方式是由控制参数向量 $|A|$ 来决定,当 $|A| \geq 1$ 时,则通过搜索的方式来寻求全局最优解。当 $|A| < 1$ 时,则选择收缩环绕的方式来寻求最优解。鲸鱼优化算法的流程如图1所示。

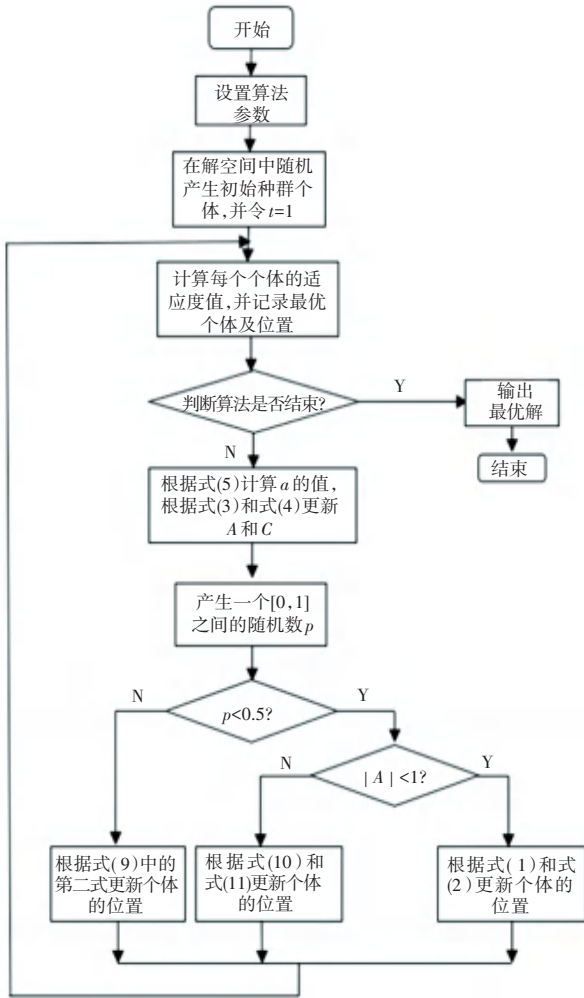


图 1 鲸鱼优化算法的流程图

Fig. 1 Flow chart of the Whale Optimization Algorithm

2 WOA-LSTM 模型

2.1 LSTM 预测模型

LSTM 神经网络首次提出于 1997 年, 传统的 RNN 会出现梯度消失和梯度爆炸等问题, 在 RNN 的基础上改进的 LSTM 能够有效地避免这一类问题。LSTM 的改进之处在于该网络在原先的基础上额外增加了记忆单元, 此记忆单元能够记住过往信息并存储。另外, LSTM 拥有不错的学习能力, 能够很好地学习样本的潜在规律, 所以能够出色地处理配电网可靠性评估这一类非线性的问题。LSTM 单元结构如图 2 所示。

当 x_t 输入时, σ 和 \tanh 的作用是决定要更新的数值, 同时会生成新的数值。遗忘门 f_t 会和更新后的数值一起更新单元状态。输出 h_t 则是由更新后的单元状态 C_t 经过 \tanh 函数和输出门中 o_t 一起运算后得到的。遗忘门 f_t 根据上一个时刻的状态 C_{t-1}

决定信息的保留还是丢失。此时, 研究中涉及到的数学公式可写为:

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

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

$$a_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (14)$$

$$C_t = f_t * C_{t-1} + i_t * a_t \quad (15)$$

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

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

其中, x_t 为输入向量; h_t 为输出向量; i 表示输入门; o 表示输出门; f 表示遗忘门; C_t 表示当前的时刻状态; C_{t-1} 表示上一时刻的状态; h_{t-1} 表示上一时刻的输出; h_t 表示当前隐藏层单元的输出; σ 表示 sigmoid 激活函数; \tanh 表示正切函数; W 表示权重矩阵; b 表示偏差向量。

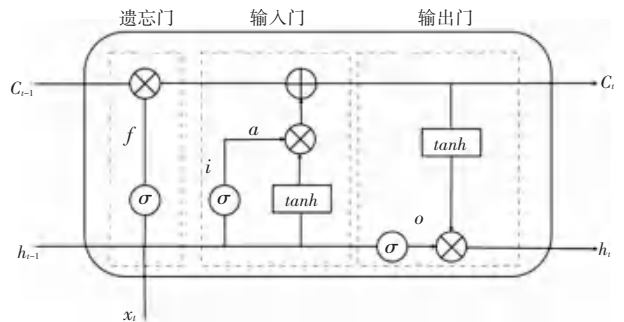


图 2 LSTM 的单元结构

Fig. 2 The unit structure of LSTM

LSTM 关键参数的选取会影响影响配电网可靠性评估的精度, 则需要对模型的参数进行正确选取。鲸鱼优化算法相比其他优化算法具有更加简单的原理, 更少的参数, 以及更强的全局搜索能力等优点, 所以对于处理非线性的问题具有一定的优势, 可用于对 LSTM 模型参数的选取。

2.2 WOA-LSTM 建模步骤

若采用单一的 LSTM 模型进行预测, 最后的结果往往不是很好, 这是因为 LSTM 的迭代次数 k , 学习率 ε 和神经元数量 L_1 、 L_2 的取值对模型的精度有很重要的影响, 如果这 4 个参数选取不合理的话, 将会导致建模结果误差大。因此, 利用 WOA 较强的寻优能力对 LSTM 模型的 4 个参数 k 、 ε 、 L_1 和 L_2 进行寻优, 得到最优参数, 以提高建模的精度。WOA-LSTM 模型流程图如图 3 所示, 具体步骤如下:

(1) 首先对配电网可靠性的数据进行归一化处理。

(2) 设定模型的参数, 分别为变量数 dim 、鲸鱼数量 $SearchAgents_no$ 、变量下限 lb 和变量上限 ub 、最大迭代次数 $t_{MaxIter}$ 。

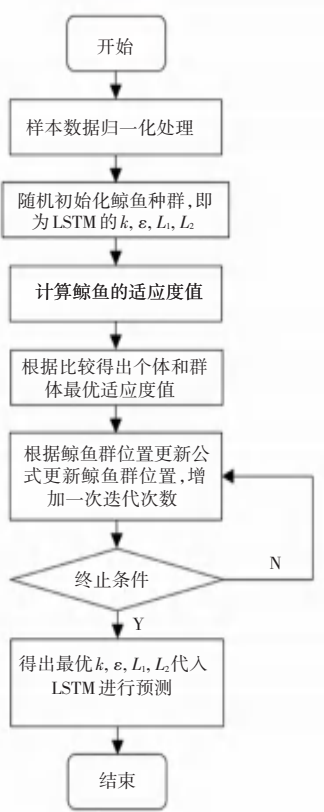


图3 WOA-LSTM 建模流程图

Fig. 3 WOA-LSTM modeling flowchart

(3) 初始化种群, 令 $n = SearchAgents_no$, 鲸鱼的位置如下式:

$$X = \begin{pmatrix} \hat{x}_{1,1} & \hat{x}_{1,2} & \hat{x}_{1,3} & \hat{x}_{1,4} & \cdots & \hat{x}_{1,dim} \\ \hat{x}_{2,1} & \hat{x}_{2,2} & \hat{x}_{2,3} & \hat{x}_{2,4} & \cdots & \hat{x}_{2,dim} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \hat{x}_{n,1} & \hat{x}_{n,2} & \hat{x}_{n,3} & \hat{x}_{n,4} & \cdots & \hat{x}_{n,dim} \end{pmatrix} \quad (18)$$

计算鲸鱼的第一个随机种群位置 X_0 , 迭代次数 t 取 1:

$$X_0(i, j) = (ub(i) - lb(i)) \times rand(i, j) + lb(i) \quad (19)$$

其中, $X_0(i, j)$ 为式(18)第 i 行第 j 列的值; $ub(i)$ 和 $lb(i)$ 为第 i 个座头鲸的上限和下限; $rand(i, j)$ 为 0 到 1 之间的随机数。

(4) 选取适应度函数: 鲸鱼的位置用于表示 LSTM 模型的参数 L_1, L_2, ε, k , 即 $X(i, 1), X(i, 2), X(i, 3)$ 和 $X(i, 4)$ 。因此将 $X(i, 1), X(i, 2), X(i, 3), X(i, 4)$ 代入 LSTM 模型对配电网可靠性进行建模, 选择 $RMSE$ 作为模型的适应度值, $RMSE$ 计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (20)$$

其中, y'_i 表示预测值, y_i 表示真实值。

(5) 利用 WOA 寻优得到最优 L_1, L_2, ε, k 。

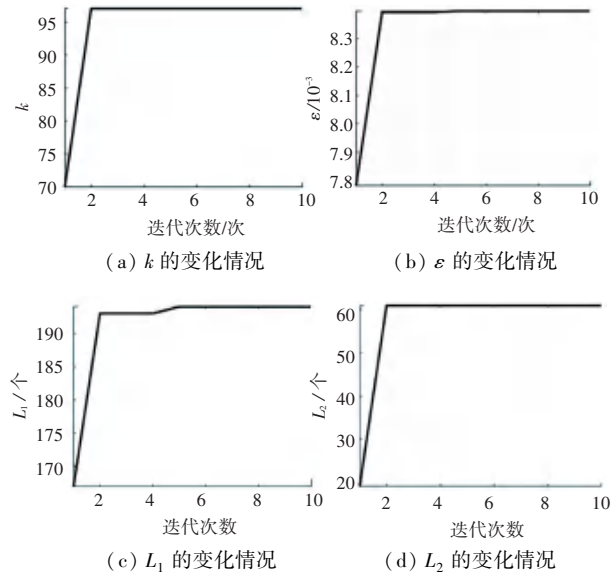
(6) 将寻优得到的 k, ε, L_1, L_2 代入 LSTM 得到配电网可靠性评估的输出。

3 模型验证

本文将模型的输入分为 3 类, 即: 配电网网架结构、配电网元件可靠性参数(线路、变压器、断路器等的故障率及平均故障修复时间)、配电网线路参数(线路长度、线路故障率及线路的类型等)。模型的输出为以下 4 个可靠性指标: 系统平均停电频率指标(System average interruption frequency index, SAIFI)、系统平均停电持续时间指标(System average interruption duration index, SAIDI)、用户平均停电累计时间(Average cumulative outage time, CAIDI)和平均用电可用率指标(Average service availability index, ASAI)作为模型的输出。

将配电网可靠性数据按照比例分为训练样本和测试样本。设置的参数如下: $dim = 4$, $SearchAgents_no = 10, t_{MaxIter} = 0, lb = [10, 0.001, 1, 1], ub = [100, 0.01, 200, 200]$ 。

采用 WOA 对 LSTM 模型的参数迭代次数、学习率和 2 层隐含层神经元个数进行寻优, 最终得到较优的 LSTM 模型参数, 如图 4 所示, 其中 $k = 97, \varepsilon = 0.0084, L_1 = 194, L_2 = 61$ 。

图4 参数 k, ε, L_1, L_2 的变化情况Fig. 4 Changes of parameters k, ε, L_1, L_2

3.1 评价指标和仿真结果

为了更好地描述模型的性能, 将均方根误差作为模型的评价指标。数学公式具体如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{y} - y_i)^2}{N}} \quad (21)$$

其中, \hat{y} 为预测值, y_i 为真实值。

WOA-LSTM 模型的预测值与真实值的比较曲线如图 5 所示。由图 5 可以看出, 真实值与预测值十分地接近。可以说明该模型可以很好地用来做配电网可靠性评估。

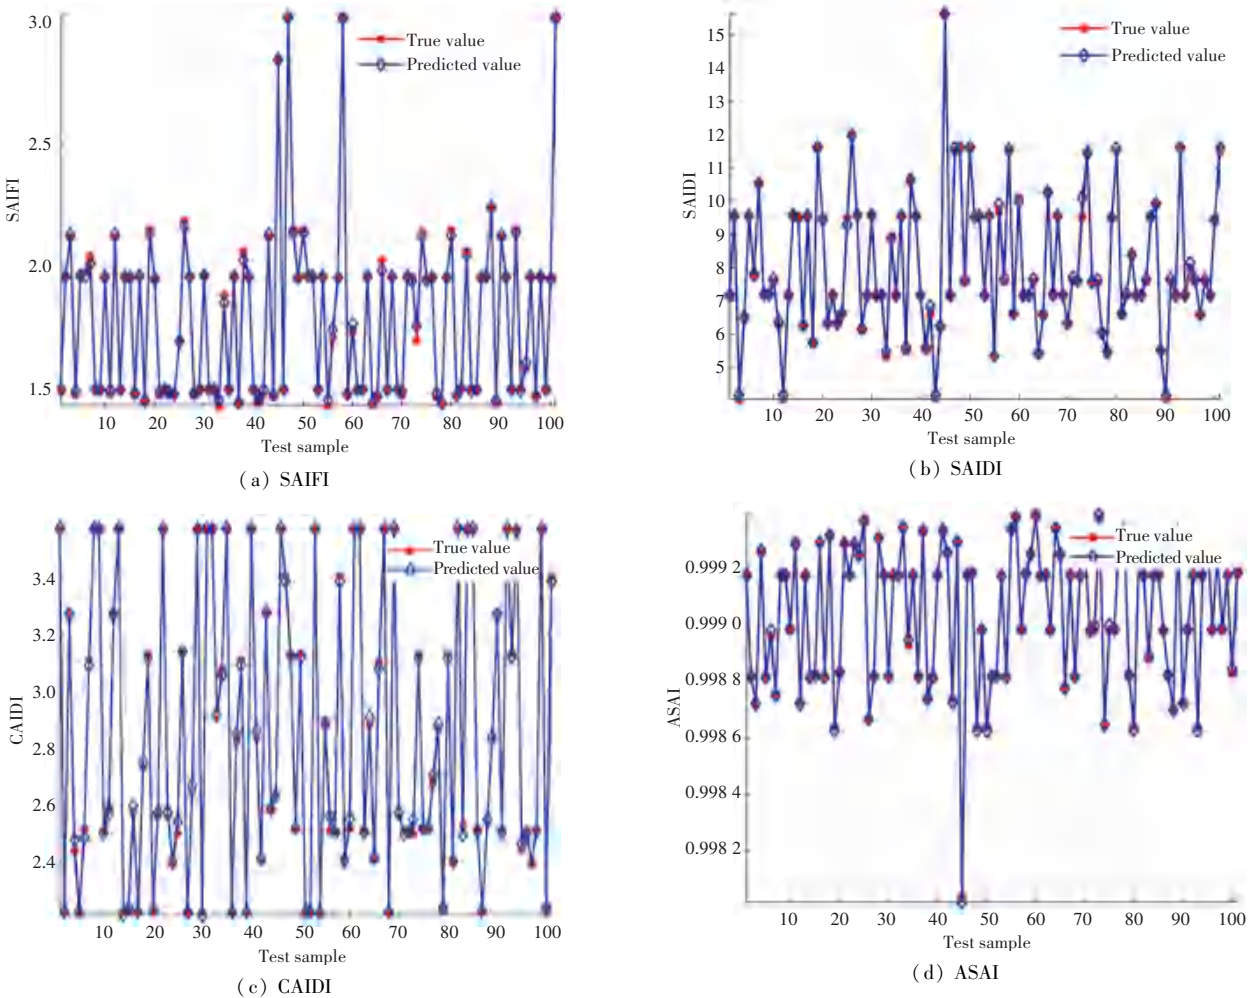


图 5 WOA-LSTM 模型真实值与预测值对比

Fig. 5 Comparison of real and predicted values of WOA-LSTM model

3.2 模型性能对比

为了验证 WOA-LSTM 模型的性能, 与传统的蒙特卡洛法、深度信念网络模型和 LSTM 模型进行对比分析, 得到基于 Monte Carlo、DBN、LSTM 和 WOA-LSTM 的 SAIFI、CAIDI、SAIDI 和 ASAI 指标的测试集结果如图 6 所示。图 6 中, 横坐标为 101 个测试集样本点, 纵轴为对应的指标。从图 6 中可以看出, WOA-LSTM 的预测结果与真实值最为接近, 效果最好。

表 1 给出了 Monte Carlo、DBN、LSTM 和 WOA-LSTM 模型的 RMSE 值。从图 6 和表 1 可以看出, 相比其他模型, WOA-LSTM 模型的性能最优。选择其

中一个配电网可靠性指标 SAIFI 来评价这 4 个模型, Monte Carlo 模型的 RMSE 值为 0.472 7, DBN 模型的 RMSE 值为 0.064 3, LSTM 模型的值为 0.051 8, 而 WOA-LSTM 模型的 RMSE 值为 0.013 7, 由此则可以看出 WOA-LSTM 模型的性能更好, 精度更高。

表 1 基于 Monte Carlo、DBN、LSTM 和 WOA-LSTM 的 RMSE 值

Tab. 1 RMSE values based on Monte Carlo, DBN, LSTM and WOA-LSTM

	Monte Carlo	DBN	LSTM	WOA-LSTM
SAIFI	0.472 700	0.064 300	0.051 800	0.013 700 0
SAIDI	3.987 600	1.150 200	0.336 600	0.091 800 0
CAIDI	0.675 400	0.146 500	0.056 300	0.015 100 0
ASAI	0.000 445	0.000 062	0.000 052	0.000 007 3

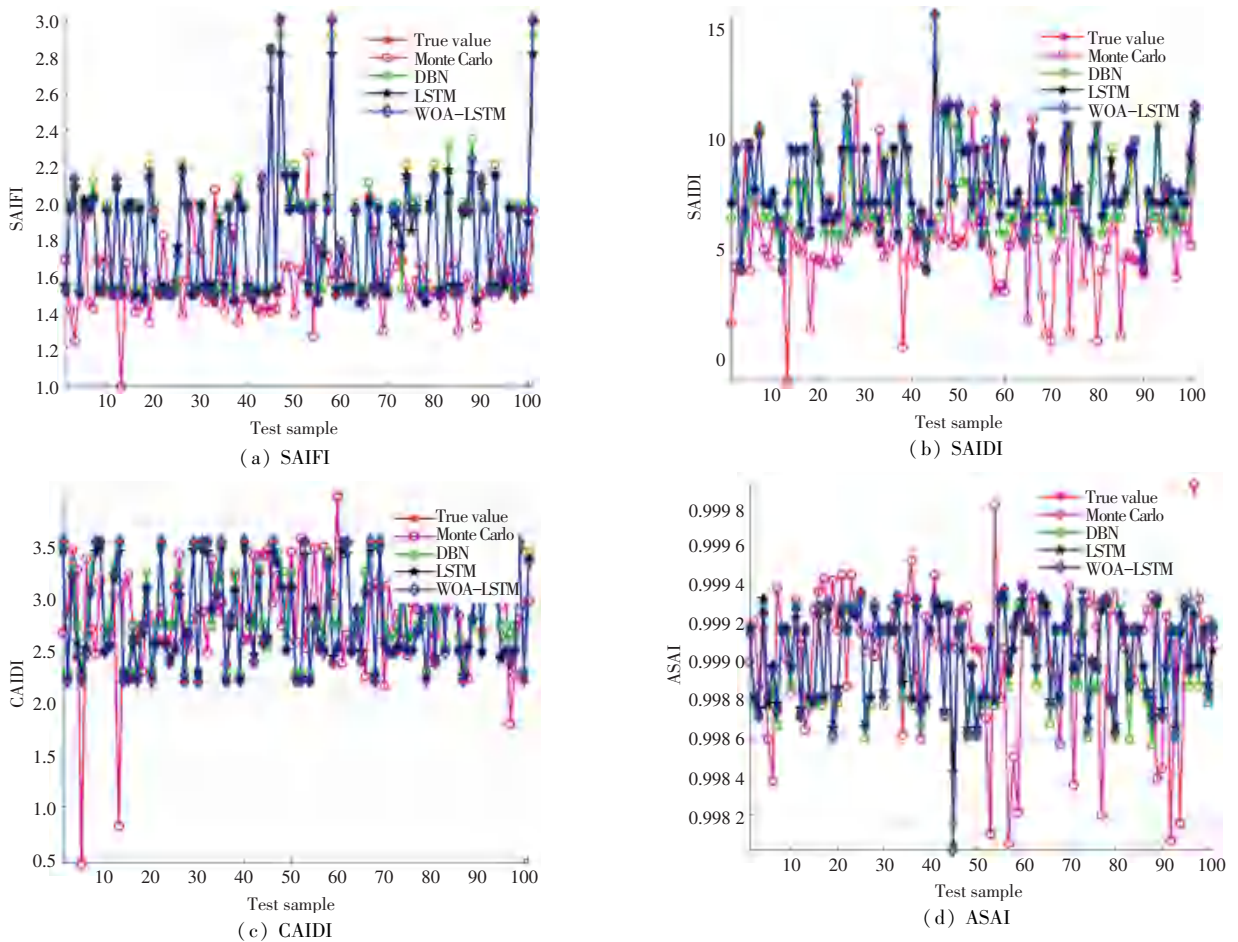


图6 不同模型预测的可靠性指标曲线

Fig. 6 Reliability index curves predicted by different models

4 结束语

配电网可靠性数据具有十分复杂的特性,每个时间段的可靠性数据都是不一样的,使用 LSTM 神经网络进行评估得到了比较理想的效果,但采用没有优化前的 LSTM 网络评估效果不是很理想。本文采用鲸鱼优化算法优化 LSTM 网络进行配电网可靠性评估,对 LSTM 模型的学习率、隐藏层节点数和迭代次数进行寻优,得到最佳的模型用于配电网可靠性评估。实验证明,WOA-LSTM 模型的精度相比其他模型效果更好,精度更高,一定程度上说明了深度学习方法在配电网可靠性分析的应用领域具有很大发展潜力。

参考文献

- [1] 葛少云,王浩鸣,徐栋. 基于蒙特卡洛模拟的分布式风光蓄发电系统可靠性分析[J]. 电网技术,2012,36(4):39-44.
- [2] BILLINTON Z, XIULI W, XIFAN W. Reliability evaluation of complicated distribution systems [J]. Journal - Xian Jiaotong University, 2000,34(8):9-13.
- [3] RAO R S, NARASIMHAM S V L, RAJU M R, et al. Optimal network reconfiguration of large-scale distribution system using

- harmony search algorithm [J]. IEEE Transactions on power systems, 2010,26(3):1080-1088.
- [4] 田洪迅,王宏刚,万涛,等. 基于 BP 神经网络的配电网可靠性关联因素灵敏度计算方法[J]. 电力系统保护与控制,2017,45(19):71-77.
- [5] ZHANG B, HE J, JIANG Y. Safety performance of large grounding grid with fault current injected from multiple grounding points [J]. IEEE Transactions on Industry Applications, 2015,51(6):5116-5122.
- [6] GREGORIO M D, JAVIER C, ARROYO J M. Distribution Network Expansion Planning with an Explicit Formulation for Reliability Assessment [J]. Transactions on Power Systems, 2017, 99(1): 95-99.
- [7] TANG Yong. The analysis of distribution system reliability based on artificial neural network [J]//2011 IEEE 3rd International Conference on Communication Software and Networks, Xi'an, China; IEEE, 2011:670-672.
- [8] 郑海峰,黄泽琦.考虑负荷时序特性的含主变配电网可靠性分析[J]. 电力系统及其自动化学报,2018,30(04):144-150.
- [9] HEIDARI A, AGELIDIS V G, POU J, et al. Reliability worth analysis of distribution systems using cascade correlation neural networks[J]. IEEE Transactions on Power Systems, 2018, 33(1):412-420.
- [10] HINTON G E. A practical guide to training restricted Boltzmann machines [J]. Momentum,2012,9(1):599-619.

(下转第 117 页)