

基于CA-WOA-BP算法的调度数据网鲁棒性预测

陈斌¹, 李泽科¹, 余斯航², 郭久煜¹, 林碧海³, 刘延华³

(1. 国网福建省电力有限公司, 福州 350003; 2. 国网福建省电力有限公司电力科学研究院, 福州 350007; 3. 福州大学计算机与大数据学院, 福州 350108)

摘要: 对电力网络鲁棒性进行评估与预测, 有利于网络管理人员感知网络系统运行现状, 及时采取措施应对可能的风险。为此提出了一种基于改进鲸鱼优化算法的电力调度数据网鲁棒性预测模型。首先, 构建了电力调度数据网鲁棒性指标体系, 并采用字段提取及公式映射等方法, 实现了面向指标体系的数据降维处理; 此外, 进一步研究了基于混沌映射与自适应权重的WOA-BP改进算法(CA-WOA-BP), 实现了电力网络鲁棒性预测方法。实验结果表明, 与WOA-BP算法相比, 所提出的改进算法加快了预测模型的收敛速度, 并克服了陷入局部最优的情况, 同时将预测值误差百分比降低了5.3%, 有助于用户更准确及时地感知电力调度数据网系统鲁棒性的态势。

关键词: 电力调度数据网; 鲸鱼优化算法; 混沌映射; 自适应权重; 网络鲁棒性预测

Robustness Prediction of Dispatching Data Network Based on CA-WOA-BP Algorithm

CHEN Bin¹, LI Zeke¹, YU Sihang², GUO Jiuyu¹, LIN Bihai³, LIU Yanhua³

(1. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350003, China; 2. Electric Power Research Institute of State Grid Fujian Electric Power Co., Ltd., Fuzhou 350007, China; 3. College of Computer and Data Science, Fuzhou University, Fuzhou 350108, China)

Abstract: Evaluation and prediction of power network system robustness are conducive to system managers' ability to perceive the current status of network system operations and take timely measures to cope with potential risks. Therefore, a robustness prediction model for power dispatching data network is proposed based on an improved whale optimization algorithm. Firstly, an evaluation index system for the robustness of the power dispatching data network is constructed and data dimensionality reduction processing is designed based on methods such as field extraction and formula mapping. Moreover, an improved chaotic mapping and adaptive weight-whale optimization algorithm (CA-WOA-BP) is proposed based on chaotic mapping and adaptive weights (WOA-BP) and a power network robustness prediction method is established. Experimental results show that compared with the WOA-BP algorithm, the proposed improved algorithm speeds up the convergence of the prediction model while overcoming the situation of falling into local optima and reduces the absolute error percentage of the predicted values by 5.3%, which helps users to discover the robustness of power dispatching data network systems more accurately and timely.

Key words: power dispatching data network; whale optimization algorithm; chaotic mapping; adaptive weights; network robustness prediction

0 引言

电力调度数据网是专为电力调度生产服务设计

的广域数据网络, 作为电力网络系统的重要组成部分, 负责传输包括电力调度实时数据、通信监测数据、生产管理数据等重要数据信息, 其安全性与可靠性严重影响着电力系统的生产管理和调度运行^[1-2]。网络鲁棒性指的是系统在遭受内部故障或外部攻击时能够维持其基本功能的能力^[3]。在实际运行中, 电力调度数据网常常面临着各种不可预测的因素, 如极端天气、设备故障、恶意攻击等, 这

基金项目: 国家自然科学基金资助项目(62072109); 国网福建省电力有限公司科技项目(ERP.52130021004Q)。

Foundation item: Supported by the National Natural Science Foundation of China (62072109); the Science and Technology Project of State Grid Fujian Electric Power Co., Ltd.(ERP.52130021004Q)。

些因素可能会导致电力调度系统的故障,甚至系统崩溃,给国家经济和社会带来不可估量的损失^[4]。为此,深入探索电力调度数据网鲁棒性的机理和影响因素,研究与改进系统鲁棒性评估及预测方法,能更及时感知网络系统的鲁棒性,有效降低电力网络系统崩溃风险。

在网络鲁棒性的评估与预测方面,目前的研究可以大致分为以下3个方向:利用复杂网络理论进行分析研究^[5];根据运行数据进行鲁棒性指标设计与计算^[6];利用机器学习等智能计算方法研究鲁棒性预测方法^[7]。冯霞等运用复杂网络理论构建了无向加权网络模型,提出一种考虑节点失效和边失效的网络鲁棒性评价策略,在不同攻击策略下评估了网络鲁棒性^[8]。赵莹等通过建立单层电网和双层相依网络模型对多种故障模式进行分析,研究了电力网络鲁棒性差异^[9]。Cai等提出了基于渗流理论的网络鲁棒性分析方法,揭示了多部分网络的二阶相变现象^[10]。在数据驱动的鲁棒性评估研究中,Barkakati等针对停电频率和停电时间等数据,提出一个新的可靠性指标分析方法,以确定电力系统鲁棒性,量化评估了输电系统的性能^[11]。Zhang等提出了基于最大相关度和最小冗余度的特征选择方法,对电力系统鲁棒性进行了预警^[12]。

综上所述,已有工作在电力网络鲁棒性研究方面取得一定进展,更关注于解决电力网络的长期规划和故障告警等问题上,较少涉及电力调度数据网鲁棒性的研究,且直接面向网络监测数据开展鲁棒性研究更为少见,这影响了所提出技术方案的实际可用性。同时,网络鲁棒性预测算法的计算性能,也是实际应用中需要解决的关键问题。

为此,本文以网络系统监测数据为分析对象,针对电力调度数据网鲁棒性快速准确预测开展研究,主要研究内容及贡献如下。

1) 结合调度数据网实际监测数据情况,构建了较为全面的网络鲁棒性指标体系,并通过公式转换计算的方法,实现了局部数据特征到系统整体评估指标的映射,缩小了后续计算的数据规模,有助于加快预测模型的训练速度。

2) 针对鲸鱼优化算法的初始解设定问题,设计了基于混沌映射^[13]与自适应权重^[14]的改进鲸鱼优化算法,提高了算法收敛速度,并避免陷入局部最优情况。

3) 将改进的鲸鱼优化算法与BP神经网络结合,提出一个新的预测算法CA-WOA-BP,通过历史数据进行训练和特征学习实现对网络鲁棒性的快速预测。

1 背景知识

本文提出基于混沌映射的自适应鲸鱼优化算法(chaotic mapping and adaptive weight-whale optimization algorithm, CA-WOA),并运用到BP神经网络中,提高预测模型的收敛速度及搜索能力。本节简要介绍BP神经网络、鲸鱼优化算法和混沌映射与自适应权重等基础技术与知识。

1.1 BP神经网络

BP神经网络(back propagation neural network)是一种基于误差反向传播算法的多层前馈网络^[15],采用误差反向传播进行模型训练,可用于模式识别、预测、分类和控制等应用场景。BP神经网络由输入层、输出层和至少一层隐藏层组成,每层由多个神经元组成。BP神经网络通过多次迭代训练和优化参数实现对样本数据的分类和预测,其基本结构如图1所示。




图1 BP神经网络结构图

Fig. 1 Diagram of BP neural network structure

1.2 鲸鱼优化算法

鲸鱼优化算法(whale optimization algorithm, WOA)是一种仿生群智能优化算法^[16-17],其基本原理是将优化问题转化为鲸鱼个体在海洋中捕捉食物的过程。每头鲸鱼的位置代表一个潜在解,通过在解空间中不断更新鲸鱼的位置,最终获得全局最优解。在算法运行过程中,鲸鱼个体分别按照其当前位置和所在种群的最优解来更新其位置,从而逐步得到全局最优解^[18]。每头鲸鱼的捕食行为包括3种:包围猎物、发泡网攻击、搜索捕食。

1) 包围猎物。鲸鱼通过回声定位获得猎物的

位置并使用包围动作进行猎食,该环节鲸鱼位置更新方式如式(1)–(2)所示。

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

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

式中: t 为目前迭代次数; A 和 C 为向量系数; $\vec{D}$ 为距离向量; $\vec{X}$ 为当前所在的位置向量; $\vec{X}^*$ 为当前最优解的位置向量; $||$ 代表求绝对值。其中 A 和 C 的计算表达式如式(3)–(4)所示。

$$A = 2a \cdot r_1 - a \quad (3)$$

$$C = 2 \cdot r_2 \quad (4)$$

式中: a 为递减系数,在整个迭代过程中 a 由 2 线性下降到 0; r_1 和 r_2 为在 $[0, 1]$ 区间中的随机数。

2) 发泡网攻击。该动作模拟了鲸鱼使用吐气泡进行捕食的行为,在这个环节中可采取两种位置更新方法,分别为收缩包围机制和螺旋更新。其计算方法如式(5)所示。

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - A \cdot D, p < 0.5 \\ \vec{X}^*(t) + D \cdot e^{b_1} \cos 2\pi l, p \geq 0.5 \end{cases} \quad (5)$$

式中: D 为距离系数; p 为 $[0, 1]$ 之间均匀分布的随机数; l 为 $[-1, 1]$ 之间的随机数; b_1 为对数螺旋形状常数。

3) 搜索捕食。当系数 $A \geq 1$ 时,表示该鲸鱼在收缩包围圈之外,此时进行随机搜索;当 $A < 1$ 时,该鲸鱼在包围圈内,选择螺旋包围搜索。此时随机搜索的更新公式如式(6)所示。

$$\vec{X}(t+1) = \vec{X}_{\text{rand}}(t) - A \cdot |C \cdot \vec{X}_{\text{rand}}(t) - \vec{X}| \quad (6)$$

式中: $\vec{X}_{\text{rand}}(t)$ 为随机选择的一个鲸鱼位置; $\vec{X}$ 为当前所在的鲸鱼位置。

1.3 混沌映射与自适应权重

在许多智能优化算法中,需要对种群进行初始化,初始化的优劣一定程度上影响了算法速度。为了加快鲸鱼优化算法的求解速度,在算法中,本文使用混沌映射来优化初始种群的伪随机数生成。生成的混沌序列进行种群初始化、选择、交叉和变异等操作时,与伪随机数相比,将能够获得更好的效果,可以对算法的整个过程产生显著影响^[19]。特别地,在搜索空间中存在许多局部解时更容易搜索到全局最优解。图 2 为使用混沌映射生成的初始种群点分布情况示意图。

自适应权重是一种优化算法策略,通过在不同




图2 混沌映射示意图

Fig. 2 Diagram of chaotic mapping

优化变量或不同迭代步骤中分配不同的权重系数达到更好的搜索效果和更快的收敛速度。在每一代进化过程中自适应权重根据当前种群的适应度情况进行动态调整权重。如果当前代的最优适应度值小于历史最优适应度值,则更新权重的值,使其更接近历史最优适应度值。

综上所述,混沌映射和自适应权重两种方法相结合能够提升优化算法的优化性能,同时避免算法陷入局部最优解。

2 算法框架

本文所提出的 CA-WOA-BP 预测模型,将混沌映射与自适应权重方法结合,提升 BP 神经网络的计算效能,其总体框架图如图 3 所示。首先,通过分析调度数据网的监测数据,构建鲁棒性指标评价体系,并选取影响网络鲁棒性的字段进一步抽象,实现具体数据到指标数据的映射。然后,将计算后的鲁棒性指标归一化后,送入训练好的 BP 神经网络中进行网络鲁棒性预测。在 BP 神经网络训练过程中,采用混沌映射自适应鲸鱼优化算法计算权重大小,优化 BP 神经网络的训练,最后进行预测获得调度数据网鲁棒性。

3 鲁棒性指标体系

为了更好对调度数据网鲁棒性进行全面评估,需要依据当前监测数据设计科学合理的鲁棒性指标体系。同时,需要设计一个合理的监测数据抽象与转化方法,实现监测数据到指标数据的映射,为鲁棒性分析提供规范化数据来源。




图3 模型总体框架

Fig. 3 Overall model framework

在电力调度数据网中,设备节点众多,网络结构具有多层次化的特点,网络监测数据存在大量特征属性,本文将面向鲁棒性指标体系对原始监测数据进行提取和融合转换,降低数据维度,从而降低后续预测模型的计算复杂度。

分析调度数据网的监测要求,设备节点的CPU利用率将影响该节点的可用性,甚至会导致节点崩溃,进而影响网络系统的整体性能。链路负载如果出现不均衡将造成网络系统传输瓶颈,加大网络拥塞的可能性,容易造成链路故障。另外,设备丢包率、链路传输时延等参数也对调度数据网稳定运行有着重要的影响作用。

由此,借鉴已有网络鲁棒性定义思路,本文提出一个新的调度数据网鲁棒性指标体系,包括链路稳定性^[20]、传输稳定性^[21]、丢包可用性^[21]、网络连通性^[22]、设备可用性^[23],具体如表1所示。

表1中各指标的定义及计算方法如下。

1) 链路稳定性: 正常情况下的网络链路负载并不会均处于超负荷的状态,若网络中各链路负载越与平均负载越接近,说明链路业务分配越合理,链路并发压力越小,则网络传输能力越强。利用网络各链路负载数据,计算链路稳定性,其计算方法如式(7)所示。

$$L = \sqrt{\frac{\sum_{j=1}^M |b_j - \bar{b}|^2}{M}} \quad (7)$$

式中: b_j 为链路 j 的负载利用率; $\bar{b}$ 为链路的平均负载率; M 为链路数量。

表1 鲁棒性指标体系

Tab. 1 Robustness index

指标名称	描述说明
链路稳定性 L	L 越高,负载越平均,并发性越好
传输稳定性 S_D	S_D 越高,链路时延越低,服务质量越高
丢包可用性 A_{loss}	丢包越少, A_{loss} 越高,数据越不容易丢
网络连通性 C	C 越高网络传输效率越高
设备可用性 S	S 越高,设备性能越好

2) 传输稳定性: 为了确保电力调度数据网业务数据能及时送达,其传输链路要有较低的时延。传输稳定性是利用网络端到端时延数据进行网络总体传输性能分析,其计算方法如式(8)所示。

$$S_D = 1 - \frac{1}{n \times \bar{D}} \sum_{i=1}^n |D_i - \bar{D}| \quad (8)$$

式中: D_i 为网络传输时延; $\bar{D}$ 为观测到的平均网络传输时延; n 为对网络拓扑的观测次数。

3) 丢包可用性: 丢包率是指在数据传输过程中,因为某种原因导致数据包不能成功到达目的地的程度大小。若丢包率过大,将降低所传输数据的完整性,同时影响业务数据的有效送达。丢包可用性用于评估网络设备丢包对网络鲁棒性的影响。其计算方法如式(9)所示。

$$A_{\text{loss}} = \frac{M_{\text{U loss}}}{M_{\text{U loss}} + M_{\text{D loss}}} \quad (9)$$

式中: $M_{\text{U loss}}$ 为该时间段内网络丢包率小于行业标准阈值的时间; $M_{\text{D loss}}$ 为超过阈值的时间。

4) 网络连通性: 网络连通性是维持网络功能正常运转的首要因素,使用最大连通分量节点数所占比例表示网络的连通性程度,具体计算方法如式(10)所示。

$$C = \frac{c_{\text{largest}}(G)}{n} \quad (10)$$

式中: $c_{\text{largest}}(G)$ 为网络最大连通分量包含的节点数; n 为网络节点数量。

5) 设备可用性: 融合节点设备的重要度与CPU利用率、内存利用率,设计了基于熵权法的设备可用性计算方法。熵权法^[24-25]是一种有效的多属性决策方法,根据指标的无序程度来计算不同指标的权重。如果某个指标的样本数据之间差异程度越大,该指标提供的信息就越丰富,相应权重也就越大。本文定义了设备重要度、CPU利用率和内存利用率的计算方法,具体如式(11)~(13)所示。

$$p_{ij} = \frac{a_{ij}}{\sum_{i=1}^N a_{ij}} \quad (11)$$

$$E_j = -\frac{1}{\ln N} \sum_{i=1}^N p_{ij} \ln p_{ij} \quad (12)$$

$$w_j = \frac{1 - E_j}{n - \sum_{j=1}^m E_j} \quad (13)$$

式中： a_{ij} 为第 j 个指标的第 i 个属性值； p_{ij} 为第 j 个指标下第 i 个属性值所占的比重； N 为属性值的数量； E_j 为第 j 个指标的信息熵； m 为指标数量； w_j 为第 j 个指标的权重。

由上面的3个影响要素，给出设备可用性的具体计算方法，如式(14)所示。

$$S = \frac{\sum_{i=1}^n (w_1 \times i_i + w_2 \times c_i + w_3 \times m_i)}{n} \quad (14)$$

式中： i_i 为节点 i 的重要度； c_i 为节点 i 的CPU利用率； m_i 为节点 i 的内存利用率； w_1 、 w_2 、 w_3 分别为三者的权重系数； n 为节点数量。

4 基于混沌映射的自适应鲸鱼优化算法

在BP神经网络中，每个神经元都有一组连接权重和阈值，利用优化算法不断调整这些参数，使输出结果能够尽可能接近真实结果，从而提高模型的精度和泛化能力。为了加快BP神经网络收敛速度，避免其陷入局部最优的问题，本文采用混沌映射与自适应权重结合的方法，提出一种新的鲸鱼优化算法，来优化BP神经网络的计算。

首先，将BP神经网络的预测均方误差的平均值作为适应度函数，提高鲸鱼优化算法对网络权重等参数的优化能力，从而提升BP神经网络的预测准确度。适应度函数值越小表明计算模型的预测精度越高，则训练越准确。适应度函数 F_{it} 的计算如式(15)所示。

$$F_{it} = \frac{M_{SE-train} + M_{SE-test}}{2} \quad (15)$$

式中： $M_{SE-train}$ 为训练集均方误差； $M_{SE-test}$ 为测试集均方误差。

其次，由于Cubic map^[26]混沌映射具有初值不敏感、遍历均衡、收敛较快等优点，能够输出高度随机的结果，即使在初值不为0的情况下也能产生混沌。同时，Cubic map混沌映射具有良好随机性

和全局优化能力，在一定程度上能克服陷入局部最优解的问题。为此，本文利用Cubic map混沌映射生成鲸鱼优化算法的初始化鲸鱼位置，设置各初始参数，Cubic map混沌映射表达式如式(16)所示。

$$x_{k+1} = \rho(1 - x_k^2) \quad (16)$$

式中： ρ 为随机控制变量； x_{k+1} 为由 x_k 产生的新的随机值。

对各代的鲸鱼个体按照其规则进行位置更新时，采用自适应权重的方法，自适应权重的表达式如式(17)所示。

$$w = w_{\min} + m(w_{\max} - w_{\min})e^{-\frac{t}{m_g}} \quad (17)$$

式中： $w_{\min}$ 、 $w_{\max}$ 分别为惯性权重的初始值和最终值； t 为在当前迭代的次数； m_g 为最大代数。

通过以上分析可知，Cubic map混沌映射能够用以生成初始化鲸鱼种群，在进化迭代中使用自适应权重更新位置信息，能够改进优化算法以达到更好的优化效果。

本文所设计的改进WOA算法，步骤如下。

1) 输入：种群大小 n 、迭代次数 max_iter 、解空间上界 ub 、下界 lb ；

2) 输出：优化后的BP神经网络权值及阈值。

(1) 使用式(12)进行混沌映射初始种群构建 pos 、初始化 $leader_pos$ 、 $leader_score$

(2) FOR i in range(max_iter):

(3) 检查个体是否越界，若越界则将越界值改为上下界

(4) $fit(i) = fitness(pos(i))$

(5) IF $fit(i) < leader_score$

(6) 对 $leader_pos$ 与 $leader_score$ 进行更新

(7) 计算式(17)进行自适应权重参数更新

(8) 对每一个个体进行多维度的循环运算

(9) 根据式(5)选择包围机制或螺旋更新

(10) END FOR

5 基于CA-WOA-BP神经网络的鲁棒性预测模型

将CA-WOA算法与BP神经网络结合，设计了一种改进BP神经网络预测模型，即CA-WOA-BP，训练后对网络鲁棒性进行预测。其基本流程如图4所示。

如图4所示，在参数初始化时，使用CA-WOA




图4 CA-WOA-BP预测流程图

Fig. 4 CA-WOA-BP prediction flowchart

算法进行BP神经网络权值及阈值的寻优,能找到具有更好表现效果的初始参数,希望能加快预测模型的收敛速度,同时避免预测模型陷入局部最优解。

利用CA-WOA传递的参数,BP神经网络采用前向传播和反向传播能力,进一步进行调整以达到更好训练效果。

在前向传播阶段,将抽取到的5维指标数据作为输入数据,通过网络进行正向传递,最终输出值则为鲁棒性预测值。

在反向传播阶段,先计算输出误差,再将误差分配给每一层中的每个神经元。每个神经元将根据误差进行权重的校正,计算每个神经元的误差,从输出层开始再反向传递到前一层神经元,最终更新每个连接的权重值。重复进行前向传播和误差计算,直到误差达到预设的精度要求,或训练次数达到预设最大值。

这里选择了单隐藏层的BP神经网络,并选取网络模型参数,其中输入层结点数量为5,输出层结点数量为1,隐藏层结点根据经验公式来确定,如式(18)所示。

$$h = \sqrt{f + g} + k \quad (18)$$

式中: h 为隐藏层结点数量; f 为输入层结点数量;

g 为输出层结点数量; k 为 $[1, 10]$ 之间的任意整数。

6 实验与结果分析

6.1 实验数据

使用某地区电力调度数据网作为实验对象,该数据网涉及4 359个节点,节点间连接关系共4 259条,采用核心层、汇聚层、接入层的分层设计结构,核心层节点仅与汇聚层节点存在上下相连关系,汇聚层节点的节点向上接入核心层、向下与接入层节点相连,而接入层的节点仅向上与汇聚层相连。

实验中通过ping方式动态判断节点状态、使用SNMP协议采集等对数据进行采集。其中动态运行数据(CPU利用率、内存利用率等)为每5 min采集一次,单个断面可产生运行数据共165万条记录约350 MB,单日运行数据量共47亿条记录,约10 GB大小。

相关的数据属性及部分数据样本,描述如表2所示。

表2 样本数据说明

Tab. 2 Sample data description

序号	字段名	取值样例及描述
1	设备ID	18位字符串,10152035000000XXXX
2	设备类型	0:核心设备 1:汇聚设备 2:接入设备
3	CPU利用率	取值范围0~1
4	内存利用率	取值范围0~1
5	丢包率	取值范围0~1
6	平均时延	不小于0
7	节点状态	1表示在线,0表示失效
8	链路ID	18位字符串,10067035000000XXXX
9	链路负载	取值范围0~1
10	链路状态	1表示正常,0表示失效
11	源设备ID	设备ID
12	目标设备ID	设备ID
13	节点鲁棒性	取值范围0~1

为了验证预测算法的准确性,抽取1 000条数据作为样本数据,按9:1划分为测试集与验证集。经过分析与计算,由样本数据所构成的网络系统,其对应的指标数据计算结果如表3所示。

6.2 实验评价指标

本文采用平均绝对误差MAE(其值用 M_{AE} 表示)、均方根误差RMSE(其值用 R_{MSE} 表示)、均方

表 3 样本数据对应的指标数值

Tab. 3 Index values of sample data

C	S	L	S_D	A_{loss}
0.911	0.943	0.664	0.672	0.779
0.833	0.592	0.621	0.977	0.730
0.853	0.513	0.956	0.928	0.826
0.920	0.560	0.686	0.871	0.692
0.543	0.925	0.534	0.750	0.637
0.799	0.589	0.779	0.742	0.818
0.735	0.540	0.636	0.615	0.673

误差 MSE(其值用 M_{SE} 表示)及平均绝对百分比误差 MAPE(其值用 M_{APE} 表示)4 种评价指标衡量模型的准确性,具体计算如式(19)~(22)所示。

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*| \quad (19)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2} \quad (20)$$

$$M_{SE} = \frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n} \quad (21)$$

$$M_{APE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - y_i^*|}{y_i} \quad (22)$$

式中: y_i 为预测值; y_i^* 为真实值; n 为数据数量。

由计算公式看出,每个评价指标的值越小,则说明预测模型的准确度越高。

6.3 进化曲线实验

由图 5 可以看出,使用 CA-WOA 算法在第 5 轮就收敛为最优值,而未使用改进方法的 WOA 则需要 25 轮才使适应度函数值最小。同时,继续进行进化,原 WOA 算法误差比 CA-WOA 更高,更容易陷入了局部最优解状态。

6.4 预测准确性实验

为验证预测算法的性能,别采用 WOA 算法和 CA-WOA 算法,与 BP 神经网络结合进行鲁棒性预测实验,并进行结果对比。实验中,抽取样本数据中的 10%,即 100 条数据,按照 1—100 进行编号,以观察预测值与真实值的差距,样本数据预测结果如图 6 所示。

由图 6 可以看出,相对 WOA 算法,基于 CA-WOA 算法的预测算法更加准确,且差距波动较小,体现了预测算法的稳定性,能有效避免因为某些数值变化而产生较大预测误差的风险。

为了更直观对比优化算法的稳定性,分别计算




图 5 进化曲线对比

Fig. 5 Comparison of evolution curves




图 6 样本数据预测准确性对比

Fig. 6 Prediction accuracies comparison of sample data

二者与真实值的均方误差,并绘制对比曲线,结果如图 7 所示。

如图 7 所示,WOA 算法在均方误差方面呈现




图 7 样本数据预测误差对比

Fig. 7 Prediction error comparison of sample data

出更大波动性,单个样本中均方误差最高达到了0.23;而CA-WOA算法的均方误差最高仅为0.11,显然具备了更好的算法稳定性。

同时,本文针对6.2中的算法评价指标进行了实验对比,具体结果如表4所示。分析可见,对比WOA算法,基于CA-WOA算法的预测模型实现了MSE指标降低了0.057、MAPE指标减少了5.3%、RMSE与MAE均下降到原来的50%以下,进一步验证了CA-WOA-BP预测算法的有效性。

表4 预测算法误差对比

Tab. 4 Comparison of prediction errors

算法	RMSE值	MAPE值	MAE值	MSE值
WOA-BP预测	0.083	9.01 %	0.064	0.069
CA-WOA-BP预测	0.036	3.71 %	0.028	0.012

7 结语

针对调度数据网鲁棒性的有效评测,本文提出了基于混沌映射与自适应权重的改进鲸鱼优化算法,进而应用到BP神经网络预测模型中,实验结果表明,所提出的预测算法实现了对调度数据网络鲁棒性的准确预测,且预测模型也具备更好的稳定性,有良好的实际应用价值。

下一步,将在本文基础上研究面向智能电网的鲁棒性优化及控制决策方法,进一步提高调度数据网的网络弹性,更好保障电力系统的安全运行能力。

参考文献

- [1] 李泽科,徐志光,余斯航,等.电力调度数据网可靠度评估方法[J].数据与计算发展前沿,2022,4(5):87-97.
LI Zeke, XU Zhiguang, YU Sihang, et al. Reliability evaluation method for power dispatching data network [J]. Frontiers of Data & Computing, 2022, 4(5):87-97.
- [2] SHARKEY T C, NURRE P S G, EISENBERG D A, et al. In search of network resilience: an optimization-based view [J]. Networks, 2021, 77(2): 225-254.
- [3] 李鑫,汪隆君.基于持续时间马尔科夫链的配电信息物理系统可靠性评估[J].广东电力,2023,36(4):41-48.
LI Xin, WANG Longjun. Reliability assessment of cyber-physical distribution system based on continuous-time Markov chains [J]. Guangdong Electric Power, 2023, 36(4): 41-48.
- [4] 楼洋,李均利,李升,等.复杂网络能控性鲁棒性研究进展[J].自动化学报,2022,48(10):2374-2391.
LOU Yang, LI Junli, LI Sheng, et al. Recent progress in controllability robustness of complex networks [J]. Acta Automatica Sinica, 2022, 48(10): 2374-2391.
- [5] 胡鑫,陈信,江海敏.电力调度数据网网络安全防护技术研究[J].自动化技术与应用,2018,37(5):20-23.
HU Xin, CHEN Xin, JIANG Haimin. Research on network security protection technology of power dispatching data network [J]. Techniques of Automation and Applications, 2018, 37(5):20-23.
- [6] WANG S, ZHANG J, YUE X. Multiple robustness assessment method for understanding structural and functional characteristics of the power network [J]. Physica A: Statistical Mechanics and its Applications, 2018(510): 261-270.
- [7] ZHANG Q, LI X, LIU X, et al. Data-driven risk assessment early-warning model for power system transmission congestions [C]//2022 12th International Conference on Power, Energy and Electrical Engineering (CPEEE), December 23, 2022, Guangzhou, China. New York: IEEE, 2022: 201-206.
- [8] 彭寒梅,彭紫洁,苏永新,等.基于LSSVM的电-气区域综合能源系统短期可靠性评估[J].电力系统自动化,2023,47(4):69-77.
PENG Hanmei, PENG Zijie, SU Yongxin, et al. Short-term reliability evaluation of electricity-gas regional integrated energy system based on least squares support vector machine [J]. Automation of Electric Power Systems, 2023, 47(4): 69-77.
- [9] 冯霞,贾宏臻.考虑节点失效和边失效的航空网络鲁棒性[J].北京交通大学学报,2021,45(5):84-92.
FENG Xia, JIA Hongcan. Aviation network robustness considering node failure and edge failure [J]. Journal of Beijing Jiaotong University, 2021, 45(5): 84-92.
- [10] 赵莹,李琰,徐天奇.基于复杂网络的电力信息相依网络鲁棒性研究[J].云南民族大学学报(自然科学版),2022,31(1):76-80.
ZHAO Ying, LI Yan, XU Tianqi. Research on the robustness of power information dependent networks based on complex networks [J]. Journal of Yunnan University of Nationalities (Natural Sciences Edition), 2022, 31(1):76-80.
- [11] CAI Q, ALAM S, PRATAMA M, et al. Robustness evaluation of multipartite complex networks based on percolation theory [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 51(10): 6244-6257.
- [12] BARKAKATI M, PAL A. A comprehensive data-driven outage analysis for assessing reliability of the bulk power system [C]//2019 IEEE Power & Energy Society General Meeting (PESGM), July 26-30, 2019, Denver, CO, USA. New York: IEEE, 2019: 1-5.
- [13] 闫文浩,姜子敬,黄欣,等.广义二维多项式混沌映射及其在信息传输中的应用[J].通信学报,2022,43(9):80-89.
YAN Wenhao, JIANG Zijong, HUANG Xin, et al. Generalized 2D polynomial chaotic map and its application in information transmission [J]. Journal on Communications, 2022, 43(9): 80-89.
- [14] 杨国华,祁鑫,贾睿,等.基于CEEMD-SE的CNN&LSTM-GRU短期风电功率预测[J].中国电力,2024,57(2):55-61.
YANG Guohua, QI Xin, JIA Rui, et al. Short-term wind power forecast based on CNN&LSTM-GRU model integrated with CEEMD-SE algorithm [J]. Electric Power, 2024, 57(2): 55-61.
- [15] 张沛,朱驻军,刘翌,等.基于RReliefF-BP网络的新型电力系统静态电压稳定在线评估方法[J].南方电网技术,2023,17

- (3):65–74.
- ZHANG Pei, ZHU Zhujun, LIU Zhao, et al. Online assessment method for static voltage stability of new power system based on RReliefF-BP network [J]. Southern Power System Technology, 2023, 17(3):65–74.
- [16] 荆志朋, 柴林杰, 胡诗尧. 基于改进 LSTM-VAE 的配电网异常负荷检测方法研究[J]. 电测与仪表, 2024, 61(9):71–76.
- JING Zhipeng, CHAI Linjie, HU Shiyao. Research on abnormal load detection method for distribution network based on improved LSTM-VAE [J]. Electrical Measurement & Instrumentation, 2024, 61(9):71–76.
- [17] 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.
- LI Andong, LIU Sheng. Multi-strategy improved whale optimization algorithm[J]. Application Research of Computer, 2022, 39(5): 1415–1421.
- [18] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016(95): 51–67.
- [19] 王涛, Ryad Chellali. 非线性权重和收敛因子的鲸鱼算法[J]. 微电子学与计算机, 2019, 36(1): 11–15.
- WANG T, Ryad Chellali. Whale optimization algorithm with nonlinear weight and convergence factor [J]. Microelectronics & Computer, 2019, 36(1): 11–15.
- [20] 王辉, 徐强, 唐俊勇, 等. ANP 网络可用性层次化模型评估方法[J]. 西安工业大学学报, 2020, 40(5):549–559.
- WANG Hui, XU Qiang, TANG Junyong, et al. Evaluation method of hierarchical network availability model based on ANP[J]. Journal of Xi'an Technological University, 2020, 40(5):549–559.
- [21] 姚玉坤, 张本俊, 周杨. 无人机自组网中基于 Q-learning 算法的及时稳定路由策略[J]. 计算机应用研究, 2022, 39(2):531–536.
- YAO Yukun, ZHANG Benjun, ZHOU Yang. Timely and stable routing strategy based on Q-learning algorithm in UAV Adhoc network[J]. Application Research of Computers, 2022, 39(2):531–536.
- [22] 洪晟, 岳天羽, 李新建. 基于层次分析的信息物理网络多维攻击损毁评估[J]. 北京航空航天大学学报, 2022, 48(9): 1827–1835.
- HONG Sheng, YUE Tianyu, LI Xinjian. Multidimensional attack damage assessment of cyber-physical systems based on hierarchical analysis [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(9): 1827–1835.
- [23] 汪昭辰, 王增平, 相禹维, 等. 基于拓扑连通性约束遗传算法的主动解列断面搜索[J]. 电力系统保护与控制, 2022, 50(21): 149–156.
- WANG Zhaochen, WANG Zengping, XIANG Yuwei, et al. Intentional islanding section searching based on a genetic algorithm with a topological connectivity constraint [J]. Power System Protection and Control, 2022, 50(21): 149–156.
- [24] 刘东奇, 曾祥君, 王耀南. 基于信息熵的智能配电变压器终端安全态势评估[J]. 南方电网技术, 2020, 14(1):18–23.
- LIU Dongqi, ZENG Xiangjun, WANG Yaonan. Security situation assessment of intelligent distribution transformer terminal unit based on information entropy [J]. Southern Power System Technology, 2020, 14(1):18–23.
- [25] 程军照, 徐敏, 冯磊, 等. 基于 GRA-K-means++ 算法的配电网供电可靠性水平评价[J]. 南方电网技术, 2023, 17(8):113–122.
- CHENG Junzhao, XU Min, FENG Lei, et al. Evaluation of distribution network power supply reliability level based on GRA-K-means++ algorithm [J]. Southern Power System Technology, 2023, 17(8):113–122.
- [26] 张孟健, 张浩, 陈曦, 等. 基于 Cubic 映射的灰狼优化算法及应用[J]. 计算机工程与科学, 2021, 43(11):2035–2042.
- ZHANG Mengjian, ZHANG Hao, CHEN Xi, et al. A grey wolf optimization algorithm based on Cubic mapping and its application [J]. Computer Engineering & Science, 2021, 43(11): 2035–2042.

收稿日期: 2023-08-25; 网络首发日期: 2024-05-20

作者简介:

陈斌(1969), 男, 高级工程师, 硕士, 研究方向为电力调度自动化技术及管理、调度数据网和电力监控系统网络安全, lunyucb_686006@sohu.com;

李泽科(1977), 男, 高级工程师(教授级), 硕士, 研究方向为调度数据网、电力监控系统网络安全, lizeke@139.com;

余斯航(1988), 男, 高级工程师, 硕士, 研究方向为调度自动化、网络安全、调度数据网, 13600898000@139.com。