

DOI: 10.13382/j.jemi.B2306485

基于 IDBO-ARIMA 的电力变压器振动信号预测*

周亚中^{1,2} 何怡刚^{1,2} 邢致恺^{1,2} 邵凯旋^{1,2} 李紫豪^{1,2} 雷蕾潇^{1,2}

(1. 武汉大学电网环境保护全国重点实验室 武汉 430072; 2. 武汉大学电气与自动化学院 武汉 430072)

摘要:为解决电力变压器振动信号因非平稳特性而导致难以预测的问题,提出一种基于改进蜣螂优化算法的差分整合移动平均自回归预测模型。首先,利用 ADF 检验和 KPSS 检验对变压器原始振动信号进行平稳性检验,若不平稳则进行差分处理直至信号平稳。其次,通过在蜣螂优化算法中引入周期突变机制以提升算法的寻优能力,并利用改进后的蜣螂优化算法对差分整合移动平均自回归模型参数 p 和 q 进行定阶,实现对变压器振动信号的预测。最后,利用某个 0.4-/0.4-kV,15-kVA 三相双绕组干式变压器实际采集的振动数据,验证所提出模型的有效性。仿真结果表明,该模型的平均绝对百分比误差可达 3.77%,而差分整合移动平均自回归模型、长短时记忆网络、循环神经网络和卷积神经网络的平均绝对百分比误差分别为 5.34%、4.74%、5.03%、5.40%。因此,所提出的模型可以实现变压器振动信号的精准预测。

关键词: 电力变压器;振动信号预测;时间序列;回归分析;蜣螂优化算法

中图分类号: TM407 **文献标识码:** A **国家标准学科分类代码:** 470.40

Power transformer vibration signal prediction based on IDBO-ARIMA

Zhou Yazhong^{1,2} He Yigang^{1,2} Xing Zhikai^{1,2} Shao Kaixuan^{1,2} Li Zihao^{1,2} Lei Leixiao^{1,2}

(1. State Key Laboratory of Power Grid Environmental Protection, Wuhan University, Wuhan 430072, China;
2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: To solve the problem that power transformer vibration signals is difficult to predict because of the non-stationary characteristic, an autoregressive integrated moving average prediction model based on improved dung beetle optimizer algorithm is proposed. Firstly, ADF test and KPSS test are used to check the stationary of the transformer original vibration signal, and if it is not stationary, differential processing is performed until the signal is stationary. Secondly, the periodic mutation mechanism is introduced into dung beetle optimizer algorithm to improve the optimization ability of the algorithm, and the parameters p and q of autoregressive integrated moving average model are determined by improved dung beetle optimizer algorithm to realize the prediction of transformer vibration signal. Finally, the validity of the proposed model is verified by using the actual collected vibration data of a 0.4-/0.4-kV, 15-kVA three-phase double-winding dry-type transformer. The simulation result shows that the mean absolute percentage error of the model can reach 3.77%, while the mean absolute percentage error of the autoregressive integrated moving average model, long short-term memory network, recurrent neural network and convolutional neural network are 5.34%, 4.74%, 5.03% and 5.40%, respectively. Therefore, the proposed model can achieve accurate prediction of transformer vibration signal.

Keywords: power transformer; vibration signal prediction; time series; regression analysis; dung beetle optimizer algorithm

0 引言

在能源互联网^[1-3]的时代背景下,加快新型电力系统建设对我国的能源转型有着举足轻重的作用,而电力变压器作为新型电力系统的核心部件之一,其运行状态直接关系整个新型电力系统的安全稳定^[4-6]。监测变压器的运行状态对及时发现和处理变压器潜在的设备故障具有重要意义。目前,振动分析被认为是监测变压器运行状况的一种经济、无损的技术,利用加速度传感器^[7]采集的变压器振动信号,可以分析变压器内部运行状态。因此,振动信号的预测对电力变压器日常维护具有重要的理论和实际意义。

电力变压器振动信号预测在过去几年里得到了广泛关注,基于机器学习的人工智能预测是当前一种热门的预测方法,如文献[8]考虑变压器振动产生机理和影响因素,提出一种基于广义回归神经网络的变压器振动基频幅值计算方法。文献[9]在此基础上,提出将马尔科夫链和广义回归神经网络进行融合实现变压器绕组的振动预测,一定程度上提高了预测的精度。文献[10]以变压器的振动信号为测试对象,比较了长短时记忆网络、门控循环单元、双向长短时记忆网络、双向门控循环单元 4 种神经网络的预测性能,研究发现在给定批大小和学习率的情况下,双向模型通常优于单向模型。文献[11]提出了一种基于卷积神经网络和长短时记忆网络融合多信号的变压器表面振动信号预测方法,其中,卷积神经网络完成特征的提取,长短时记忆网络通过提取的特征预测变压器表面的振动信号。以上文献利用机器学习的方法实现了变压器振动信号的预测,为变压器的安全稳定运行做出了积极贡献,然而,神经网络等机器学习的方法存在过拟合的问题,无法保证该方法在预测过程中的泛化性能。同时,模型参数的选择很大程度上影响了神经网络等机器学习方法的预测精度。此外,变压器的振动信号存在非平稳特性^[12],上述方法没有考虑其对模型预测精度产生的影响,使得上述方法在进一步提升变压器振动信号预测精度上受到限制。

利用加速度传感器采集变压器的振动信号是一种时间序列,而时间序列分析^[13]作为一种成熟的预测方法,已经在光伏出力预测^[14]、负荷预测^[15]、输电线路覆冰预测^[16]等领域取得了较好的研究成果。时间序列分析的原理在于:1) 承认事物发展的延续性,通过对历史数据进行统计分析来推测事物未来的发展趋势;2) 通过对历史数据进行统计分析,消除偶然因素带来的随机波动影响。时间序列分析最大的优点在于不必深究序列的产生背景,原始序列本身所具有的时序性和自相关性已经为建立预测模型提供了足够的信息,只需要有限的样本序列,

就可建立起相当高精度的预测模型,但其存在预测模型阶数难以确定的问题^[17]。

近些年来,大量元启发式仿生优化算法^[18]的提出为解决时间序列预测模型难以定阶的问题提供了可行的思路。如根据鸟群和鱼群的觅食行为提出的粒子群优化算法(particle swarm optimization, PSO)^[19]、根据哈里斯鹰捕食猎物的行为提出的哈里斯鹰优化算法(Harris Hawks optimization, HHO)^[20]、根据鲸鱼围捕猎物的行为提出的鲸鱼优化算法(whale optimization algorithm, WOA)^[21]等,但是利用上述算法对时间序列预测模型进行定阶时都存在一定的不足,如 PSO 算法、HHO 算法容易陷入局部最优解,导致模型的预测精度不高;WOA 算法的收敛速度较慢,导致时间序列预测模型定阶时需要花费大量的时间。蜣螂优化(dung beetle optimizer, DBO)算法是由东华大学沈波教授团队在 2022 年提出^[22],该算法的灵感来自蜣螂的滚球、跳舞、繁殖、觅食和偷窃行为,相比较上述算法具有求解精度更高、收敛速度更快、稳定性能更强等优点。因此,本文拟采用 DBO 算法实现时间序列预测模型的定阶。然而,原始 DBO 算法的全局寻优能力仍存在一定的提升空间,为此,本文拟对原始 DBO 算法提出一种改进策略。

综上所述,本文提出一种基于改进蜣螂优化(improved dung beetle optimizer, IDBO)算法的差分整合移动平均自回归(autoregressive integrated moving average, ARIMA)的电力变压器振动信号预测模型。需要说明的是,本文中的“振动信号预测”指的是振动加速度的数值预测。首先,对变压器原始振动信号进行平稳性检验,若不平衡则进行差分处理。其次,通过引入周期性突变机制的方式实现对 DBO 算法的改进,使其具有更强的寻优能力,并利用 IDBO 算法对 ARIMA 模型进行定阶。最后,使用定阶后的 ARIMA 模型对电力变压器的振动信号进行预测,仿真结果表明,本文所构建的预测模型相对于其他方法具有更高的准确性。

1 算法基本原理

由于变压器是一种多震源、宽频带、振动情况复杂的电力设备,且在运行过程中存在大量的变工况,因此,变压器的振动信号具有明显的非平稳特性,传统的机器学习方法很难对其进行精准预测。此外,变压器的振动信号是加速度在不同时间上的各个数值,按照时间先后顺序排列而形成的非平稳时间序列,而 ARIMA 模型可通过差分的方式将非平稳序列转化为平稳序列,是一种分析非平稳时间序列的有效方法。

1.1 ARIMA 模型

ARIMA 模型是自回归移动平均(autoregressive

moving average, ARMA)模型的广义形式,这两个模型都可以预测时间序列中的未来值。设 y_t 表示时间序列不同时刻 t 的实际值,ARMA 模型的自回归(auto regressive, AR)部分可表示为^[23]:

$$y_t = \sum_{i=1}^p \gamma_i y_{t-i} \quad (1)$$

式中: γ_i 为 AR 的自相关系数, p 为自回归项的阶数。同时,设 ε_t 为 t 时刻的白噪声误差项,则 ARMA 模型的移动平均(moving average, MA)部分可由式(2)表示:

$$y_t = \mu + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (2)$$

式中: μ 为 y_t 的期望值, q 为移动平均项的阶数; $\theta_j (j=1, 2, \dots, q)$ 为模型参数。式(2)表明 t 点的值线性依赖于当前和过去的 q 个白噪声误差项。结合式(1)和(2),ARMA 模型可表示为:

$$y_t = \sum_{i=1}^p \gamma_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (3)$$

在实际工程中,时间序列中的值通常是不平稳的,为了捕获时间序列的平稳特性,差分方法被纳入 ARMA 模型,即为 ARIMA 模型。假设 $\Delta^d y_t$ 表示 y_t 的 d 阶差分,则 ARIMA(p, d, q)可以表示为:

$$\Delta^d y_t = \sum_{i=1}^p \gamma_i \Delta^d y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (4)$$

ARIMA 模型预测时间序列的准确度,很大程度上取决于 p 和 q 的值,而参数 p 和 q 通常是根据自相关函数和偏自相关函数来选择,然而这类方法存在自回归项、移动平均项的阶数难以确定以及预测精度不高的问题,优化算法的提出为解决 ARIMA 模型的定阶困难的问题提供了可行的思路。

1.2 改进的蜥蜴优化算法

蜥蜴优化算法的原理即是通过模拟自然界中蜥蜴的滚球、跳舞、繁殖、觅食和偷窃行为实现最优值的选择。在 1.2 节中,1)~5)为蜥蜴优化算法原理的论述,6)为本文所提出的改进策略,7)为改进后蜥蜴优化算法的所采用的适应度函数。

1) 滚球行为

蜥蜴在日常生活中为了保持粪球在直线上滚动,需要通过天体线索进行导航。为了模拟滚动球的行为,需要蜥蜴在整个搜索空间中沿着给定的方向移动。在滚动过程中,按照式(5)对蜥蜴的位置进行更新:

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \quad (5)$$

$$\Delta x = |x_i(t) - x^{\text{worst}}|$$

式中: t 表示当前的迭代次数; $x_i(t)$ 为第 i 只蜥蜴在第 t 次迭代中的位置信息; k 为偏转系数,取值范围为 $(0, 0.2]$; b 为一个常数,取值范围为 $(0, 1)$; α 为自然系数,取值 1 或者 -1, 1 表示无偏差, -1 表示偏离原来方向;

x^{worst} 表示全局最差的蜥蜴位置; Δx 用于模拟光强的变化。

2) 跳舞行为

当蜥蜴在滚动粪球的过程中遇到障碍而无法前进时,需要通过跳舞的方式重新定位,以获取新的前进路线,此时蜥蜴的位置可按式(6)进行更新:

$$x_i(t+1) = x_i(t) + \tan(\theta) |x_i(t) - x_i(t-1)| \quad (6)$$

式中: θ 为偏转角,取值范围为 $[0, \pi]$,需要说明的是,当 $\theta=0, \pi/2$ 或 π 时,蜥蜴的位置不进行更新。

3) 繁殖行为

在自然界中,蜥蜴为了能够给后代提供一个安全的生长场所,需要选择合适的产卵地点,蜥蜴繁殖的边界选择策略可结合图 1 和式(7)来进行描述:

$$Lb^* = \max(X^* \times (1-R), Lb) \quad (7)$$

$$Ub^* = \min(X^* \times (1+R), Ub)$$

式中: X^* 表示当前局部最优位置; Lb^* 和 Ub^* 分别表示产卵区域的下界和上界; $R=1-t/T_{\max}$, $T_{\max}$ 表示最大迭代次数; Lb 和 Ub 分别表示优化问题的下界和上界。需要说明的是,雌性蜥蜴产卵区域的边界范围随着迭代次数动态调整。




图 1 边界选择策略

Fig. 1 Boundary selection strategy

一旦确定了产卵区域,雌性蜥蜴在此区域内进行产卵。需要说明的是,每只雌性蜥蜴在每次迭代中只会生产一个卵球。此外,由式(7)可以看出,产卵区边界范围随 R 值动态变化,因此,在迭代过程中卵球的位置也是动态变化的,卵球的位置变化可由式(8)描述:

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - Lb^*) + b_2 \times (B_i(t) - Ub^*) \quad (8)$$

式中: $B_i(t)$ 为第 i 个卵球在第 t 次迭代时的位置信息; b_1 和 b_2 表示两个大小为 $1 \times D$ 的独立随机向量, D 表示优化问题的维数。

4) 觅食行为

从地下钻出地面觅食的蜥蜴称为小蜥蜴,可通过式(9)和(10)描述小蜥蜴的最佳觅食区域以及觅食过程中的位置变化:

$$Lb^b = \max(X^b \times (1 - R), Lb)$$

$$Ub^b = \min(X^b \times (1 + R), Ub) \quad (9)$$

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - Lb^b) + C_2 \times (x_i(t) - Ub^b) \quad (10)$$

式中: X^b 表示全局最优位置; Lb 和 Ub 为最佳觅食区域的下界和上界; $x_i(t)$ 表示第 i 只小蜣螂在第 t 次迭代中的位置信息; C_1 表示遵循正态分布的随机数; C_2 表示 $(0, 1)$ 范围内的随机向量。

5) 偷窃行为

偷取其他蜣螂粪球的蜣螂称为小偷蜣螂, 通过式(9)可以看出, X^b 是最佳食物来源, 因此, 假设 X^b 附近是最适合竞争食物的地方。在迭代过程中, 小偷蜣螂的位置更新如式(11)所示:

$$x_i(t+1) = X^b + S \times g \times (|x_i(t) - X^*| + |x_i(t) - X^b|) \quad (11)$$

式中: $x_i(t)$ 为第 i 个小偷蜣螂在第 t 次迭代时的位置信息, g 为大小为 $1 \times D$ 的服从正态分布的随机向量, S 为常数。

6) 改进策略

为了增强 DBO 算法中每个蜣螂个体的多样性, 本文对 DBO 算法做如下改进: 引入周期性突变机制, 使改进后的优化算法在解空间中能够进行较大范围的周期性跳跃, 以实现算法更为充分的寻优。改进后的 DBO 算法记为 IDBO, 其周期性突变机制如式(12)所示:

$$x_i(t+1) = x_i(t) \times [1 + A \times (0.5 - rand) \times \sigma] \quad (12)$$

$$\sigma = \begin{cases} 1 & t = nT \\ 0 & t \neq nT \end{cases} \quad n = 1, 2, 3, \dots$$

式中: A 为突变幅度; $rand$ 表示按照均匀分布 $N(0, 1)$ 随机生成的实数; T 为突变周期, 其值小于最大迭代次数; σ 是根据突变周期从一个区域搜索到另一个区域的冲量。

因此, 在滚球行为中, 式(5)可修改为:

$$x_i(t+1) = \begin{cases} x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x, & t \neq nT \\ x_i(t) \times [1 + A \times (0.5 - rand)], & t = nT \end{cases} \quad (13)$$

在跳舞行为中, 式(6)可修改为:

$$x_i(t+1) = \begin{cases} x_i(t) + \tan(\theta) |x_i(t) - x_i(t-1)|, & t \neq nT \\ x_i(t) \times [1 + A \times (0.5 - rand)], & t = nT \end{cases} \quad (14)$$

在繁殖行为中, 式(8)可修改为:

$$B_i(t+1) = \begin{cases} X^* + b_1 \times (B_i(t) - Lb^*) + b_2 \times (B_i(t) - Ub^*), & t \neq nT \\ B_i(t) \times [1 + A \times (0.5 - rand)], & t = nT \end{cases} \quad (15)$$

在觅食行为中, 式(10)可修改为:

$$x_i(t+1) =$$

$$\begin{cases} x_i(t) + C_1 \times (x_i(t) - Lb^b) + C_2 \times (x_i(t) - Ub^b), & t \neq nT \\ x_i(t) \times [1 + A \times (0.5 - rand)], & t = nT \end{cases} \quad (16)$$

在偷窃行为中, 式(11)可修改为:

$$x_i(t+1) = \begin{cases} X^b + S \times g \times (|x_i(t) - X^*| + |x_i(t) - X^b|), & t \neq nT \\ x_i(t) \times [1 + A \times (0.5 - rand)], & t = nT \end{cases} \quad (17)$$

7) 适应度函数

本文以贝叶斯信息准则 (Bayesian information criterion, BIC) 评价模型的优劣, 并将其最小值作为 IDBO 算法的适应度函数, BIC 数值越小说明模型的预测效果越好。BIC 的数值计算公式如式(18)所示:

$$BIC = -2 \times \ln(L) + (p + q + 1) \times \ln(n) \quad (18)$$

式中: L 为似然函数; n 为样本数量; p 和 q 分别是自回归项阶数和移动平均项阶数。

2 构建变压器振动信号预测模型

2.1 平稳性检验

利用 ARIMA 模型对电力变压器振动信号进行预测时, 需要先对原始信号进行平稳性检验。ADF 检验是一种常见的单位根检验方法, 其原理如式(19)~(21)所示^[24]:

$$\Delta X_t = \delta X_{t-1} + \sum_{i=1}^m \beta_i \Delta X_{t-i} + \varepsilon_t \quad (19)$$

$$\Delta X_t = \alpha + \delta X_{t-1} + \sum_{i=1}^m \beta_i \Delta X_{t-i} + \varepsilon_t \quad (20)$$

$$\Delta X_t = \alpha + \beta t + \delta X_{t-1} + \sum_{i=1}^m \beta_i \Delta X_{t-i} + \varepsilon_t \quad (21)$$

式中: ΔX_t 为 t 时刻的残差; X_{t-1} 为 $t-1$ 时刻的残差; βt 为趋势项; ε 为残差项; t 为时间变量; α 为常数项。原假设均是 $H_0: \delta=0$, 检验时按照式(21)、(20)、(19)的顺序依次进行。如果检验拒绝原假设, 则原始振动信号不存在单位根, 即为平稳时间序列, 即可停止检验, 否则继续检验, 直至检验完式(19)为止。

ADF 单位根检验方法中的备择假设是假设数据生成过程为自回归模型, 与之具有互补性的方法是 KPSS 单位根检验法, 因此本文采用 ADF 与 KPSS 联合检验的方式, 使检验结果的可靠性更高。KPSS 检验的原假设为信号平稳, 并构造 LM 统计量来判断原始信号是否平稳。通过剔除趋势项和截距项后, 令 y 为需要检验的原始振动信号, x_t 为外生变量向量序列, 则回归方程的建立如式(22)所示:

$$y_t = x_t' \delta + \mu_t \quad (22)$$

使用 OLS 法对式 (22) 中的 μ_i 进行估计, 得到 $\hat{\mu}$ 。

KPSS 通过检测 $\hat{\mu}$ 单位根的存在性, 判断原始振动信号是否平稳。LM 统计量的计算公式如式 (23) 所示:

$$LM = \frac{\sum_i \left(\sum_{r=1}^i \hat{\mu} \right)^2}{T^2 f_0} \quad (23)$$

式中: f_0 是残差频谱密度 (频率为 0)。

2.2 模型定阶

利用改进后的蜣螂优化算法对 ARIMA 模型进行定阶, 设置蜣螂种群为 30 个, 其中, 滚球和跳舞蜣螂 6 个, 繁殖蜣螂 6 个, 觅食蜣螂 7 个, 小偷蜣螂 11 个。需要说明的是, 本文以概率的方式分别进行滚球行为和跳舞行为, 具体方法为: 在 0~1 之间取一个随机数, 若小于 0.9, 则进行滚球行为, 否则进行跳舞行为。在滚球行为中的 α 取值同样采用概率的方式, 若随机数大于 0.1, α 取值 1, 否则取值 -1。此外, 偏转系数 k 取值 0.1; 参数 b 取值 0.3; 参数 S 取值 0.5; 突变幅度 A 取值 1; 突变周期 T 取值 5。选取 BIC 的最小数值为算法的适应度函数。本文通过训练得到最优阶数 p 和 q , 再利用最优阶数构建变压器振动信号的时间序列预测模型。

2.3 振动信号预测流程

本文以时间序列分析方法中的 ARIMA 模型为基础, 利用改进后的蜣螂优化算法实现 ARIMA 模型的 p 、 q 寻优, 实现变压器振动信号预测模型的构建。基于 IDBO-ARIMA 的电力变压器振动信号预测模型流程如图 2 所示, 共分为数据预处理、ARIMA 模型定阶和振动信号预测 3 个部分。

在数据预处理方面, 对原始变压器振动信号进行平稳性检验, 若不平稳则对原始信号进行差分处理直至满足平稳性要求。在 ARIMA 模型定阶方面, 将周期性突变机制引入蜣螂优化算法以提升算法的寻优能力, 利用改进后的算法实现 ARIMA 模型的 p 和 q 定阶。在振动信号预测方面, 基于稳定的时间序列, 利用定阶后的 ARIMA 模型实现电力变压器振动信号的预测, 并计算相关指标。

2.4 预测效果评价指标

基于 IDBO-ARIMA 模型的电力变压器振动信号预测方法本质是回归问题, 因此本文采用平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root mean square error, RMSE) 以及确定系数 (R^2) 这 4 类指标评价本文所提预测模型的准确性。4 类指标的计算公式如式 (24)~(27) 所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{x}_i - x_i| \quad (24)$$




图2 预测模型流程

Fig. 2 Flow chart of prediction model

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \times 100\% \quad (25)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2} \quad (26)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{x}_i - x_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (27)$$

式中: $\hat{x}_i$ 为预测值; x_i 为实际值; $\bar{x}$ 为实际样本的平均值。其中, MAE、MAPE 和 RMSE 的数值越小, 说明模型的预测效果越好; R^2 的数值越大, 说明模型越适用于数据集。

3 仿真分析

3.1 标准函数测试

为了验证所提蜣螂优化算法改进策略的有效性, 本文选取多种标准测试函数评估 DBO 算法和 IDBO 算法的性能。标准测试函数^[25]如表 1 所示, 其中, F1~F3 为高维单峰测试函数, F4~F6 为高维多峰测试函数。

为了保证测试的公平性, 每个算法的种群数和迭代次数分别设置为 30 和 200。此外, 每个算法对测试函数单独运行 20 次, 并将每次测试得到的最优值取平均, 最终的测试结果如表 2 所示。通过表 2 可以看出: 1) 最优值方面, IDBO 算法均小于 DBO 算法; 2) 标准差方面, 仅仅只在 F6 中, IDBO 算法大于 DBO 算法, 而在 F1~F5 中, IDBO 算法均小于 DBO 算法。综上所述, 改进后蜣螂优化算法的寻优能力显著提升。

表 1 标准测试函数

Table 1 Standard test function

标准函数	维数	范围	最优值
$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
$F_3(x) = \sum_{i=1}^n ix_i^4 + random[0, 1)$	30	$[-128, 128]$	0
$F_4(x) = \frac{1}{4\,000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	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	$[-32, 32]$	0
$F_6(x) = 0.1 \left\{ \frac{\sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)]}{\sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)]} \right\} + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] + \sum_{i=1}^n u(x_i, 5, 100, 4)$	30	$[-50, 50]$	0
$u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m x_i > a \\ 0 - a \leq x_i \leq a \\ k(-x_i - a)^m x_i < -a \end{cases}$			

表 2 测试效果对比

Table 2 Comparison of test result

函数	DBO		IDBO	
	最优值	标准差	最优值	标准差
F1	1.64×10^{-15}	6.69×10^{-15}	0.00	0.00
F2	8.86×10^{-9}	3.83×10^{-8}	0.00	0.00
F3	4.18×10^{-3}	4.59×10^{-3}	5.46×10^{-4}	4.31×10^{-4}
F4	2.10×10^{-13}	6.79×10^{-13}	0.00	0.00
F5	5.24×10^{-9}	2.13×10^{-8}	4.44×10^{-16}	0.00
F6	2.09	0.421	0.72	0.714

3.2 原始信号平稳性检验

利用 ARIMA 模型对变压器振动信号进行预测时需要 对原始信号进行平稳性检验,若不满足平稳性条件,则 需要进行差分处理。欠励磁是变压器常见的运行故障, 可能会导致变压器铁心损耗增高,从而引起变压器的温 升。因此,本文采用文献[10]中变压器欠励磁运行时的 实测振动数据,因受篇幅限制,本文只展示其中 4 段振动 信号,每段振动信号包含 2 000 个采样点。利用 ADF 和 KPSS 对原始振动信号进行平稳性检验,检验结果如表 3 所示。

表 3 平稳性检验结果

Table 3 Result of stationary test

振动信号	ADF	KSP	检验结果
振动信号 1	0	0	不通过
振动信号 2	0	0	不通过
振动信号 3	0	0	不通过
振动信号 4	0	0	不通过

通过表 3 可以看出 4 段原始振动信号均为不平稳序 列,需要进行差分处理。4 段原始振动信号经过一阶差 分后,ADF 的统计量为 1,KPSS 的统计量为 0,ADF 检验 和 KPSS 检验均通过,说明一阶差分后的振动信号为平 稳序列。4 段原始振动信号以及经过一阶差分后的信号 曲线如图 3~6 所示。




图 3 振动信号 1

Fig. 3 The first vibration signal

3.3 预测模型性能评估及误差分析

本文在上述每段振动信号的 2 000 个采样点中,选 取前 70%的采样点作为训练集,选取后 30%的采样点作 为测试集。4 段振动信号的预测结果分别如图 7~10 所 示,图 11 为 4 段振动信号预测的回归图,误差指标计算 结果如表 4 所示。

通过图 7~10 的预测结果中可以看出,在振动信号 变化趋势相对缓慢的部分,模型的预测结果基本都能够




图 4 振动信号 2

Fig. 4 The second vibration signal




图 5 振动信号 3

Fig. 5 The third vibration signal




图 6 振动信号 4

Fig. 6 The fourth vibration signal

拟合信号变化趋势。但在信号变化较剧烈的部分,尤其是振动信号的波峰和波谷部分,预测值与真实值存在一定偏差。通过表 4 可以看出,4 段振动信号预测值的 RMSE 均在 4.0×10^{-4} 以下,而 MAE 和 MAPE 的最大值分别为 3.01×10^{-4} 和 3.97%,以上预测精度指标验证了本文所提 IDBO-ARIMA 模型的有效性。此外,通过图 11 可以看出,4 段振动信号的回归系数均在 0.9 左右,说明输

出值与实际值的相关程度较高,进一步佐证了本文方法的有效性。




图 7 振动信号 1 预测曲线

Fig. 7 The first vibration signal prediction curve




图 8 振动信号 2 预测曲线

Fig. 8 The second vibration signal prediction curve




图 9 振动信号 3 预测曲线

Fig. 9 The third vibration signal prediction curve




图 10 振动信号 4 预测曲线

Fig. 10 The fourth vibration signal prediction curve

表 4 误差指标计算结果				
Table 4 Calculation result of error index				
振动信号	RMSE	MAE	MAPE	R^2
振动信号 1	3.58×10^{-4}	2.92×10^{-4}	3.83%	0.80
振动信号 2	3.54×10^{-4}	2.81×10^{-4}	3.65%	0.81
振动信号 3	3.59×10^{-4}	2.82×10^{-4}	3.63%	0.79
振动信号 4	3.79×10^{-4}	3.01×10^{-4}	3.97%	0.77

3.4 不同预测模型结果对比分析

为验证本文所提出模型的优越性,本文选择将 IDBO-ARIMA 模型的预测结果与 DBO-ARIMA 模型、




图 11 振动信号回归图

Fig. 11 Vibration signal regression diagram

ARIMA 模型、长短时记忆网络 (long short-term memory network, LSTM)、循环神经网络 (recurrent neural network, RNN) 以及卷积神经网络 (convolutional neural network, CNN) 进行对比,对比结果如表 5~8 所示。

表 5 不同预测模型对比 (振动信号 1)

Table 5 Comparison of different prediction model (the first vibration signal)

预测模型	RMSE	MAE	MAPE	R^2
IDBO-ARIMA	3.58×10^{-4}	2.92×10^{-4}	3.83%	0.80
DBO-ARIMA	3.77×10^{-4}	2.97×10^{-4}	3.88%	0.78
ARIMA	5.05×10^{-4}	4.05×10^{-4}	5.31%	0.60
LSTM	4.48×10^{-4}	3.63×10^{-4}	4.88%	0.69
RNN	4.78×10^{-4}	3.95×10^{-4}	5.22%	0.65
CNN	5.19×10^{-4}	4.27×10^{-4}	5.75%	0.58

表 6 不同预测模型对比 (振动信号 2)

Table 6 Comparison of different prediction model (the second vibration signal)

预测模型	RMSE	MAE	MAPE	R^2
IDBO-ARIMA	3.54×10^{-4}	2.81×10^{-4}	3.65%	0.81
DBO-ARIMA	4.09×10^{-4}	3.25×10^{-4}	4.22%	0.80
ARIMA	5.06×10^{-4}	4.09×10^{-4}	5.34%	0.61
LSTM	4.23×10^{-4}	3.49×10^{-4}	4.58%	0.72
RNN	4.6×10^{-4}	3.79×10^{-4}	4.99%	0.67
CNN	4.78×10^{-4}	3.83×10^{-4}	5.00%	0.64

表 7 不同预测模型对比 (振动信号 3)

Table 7 Comparison of different prediction model (the third vibration signal)

预测模型	RMSE	MAE	MAPE	R^2
IDBO-ARIMA	3.59×10^{-4}	2.82×10^{-4}	3.63%	0.79
DBO-ARIMA	3.69×10^{-4}	2.89×10^{-4}	3.69%	0.77
ARIMA	5.16×10^{-4}	4.11×10^{-4}	5.27%	0.57
LSTM	4.50×10^{-4}	3.70×10^{-4}	4.82%	0.67
RNN	4.64×10^{-4}	3.78×10^{-4}	4.84%	0.65
CNN	5.27×10^{-4}	4.27×10^{-4}	5.58%	0.55

表 8 不同预测模型对比 (振动信号 4)

Table 8 Comparison of different prediction model (the fourth vibration signal)

预测模型	RMSE	MAE	MAPE	R^2
IDBO-ARIMA	3.79×10^{-4}	3.01×10^{-4}	3.97%	0.77
DBO-ARIMA	3.86×10^{-4}	3.10×10^{-4}	4.11%	0.76
ARIMA	5.13×10^{-4}	4.14×10^{-4}	5.45%	0.58
LSTM	4.41×10^{-4}	3.62×10^{-4}	4.69%	0.69
RNN	4.66×10^{-4}	3.83×10^{-4}	5.07%	0.65
CNN	4.87×10^{-4}	3.89×10^{-4}	5.26%	0.62

通过表 5~8 可以看出,在振动信号 2 和振动信号 4 的预测结果中,ARIMA 模型的各项预测精度指标均低于 LSTM 网络、RNN 网络以及 CNN 网络;在序列 1 和序列 3 的预测结果中,ARIMA 模型的各项预测精度指标均低于 LSTM 网络和 RNN 网络;说明如果未利用优化算法对 ARIMA 模型进行定阶,则很难取得较高的预测精度;在振动信号 1、振动信号 2、振动信号 3 和振动信号 4 的预测结果中,DBO-ARIMA 模型的各项预测精度指标均高于 ARIMA 模型、LSTM 网络、RNN 网络以及 CNN 网络,说明利用 DBO 算法对 ARIMA 模型进行定阶,可显著提升 ARIMA 模型的预测精度;在振动信号 1、振动信号 2、振动信号 3 和振动信号 4 的预测结果中,IDBO-ARIMA 模型的各项预测精度指标均高于 DBO-ARIMA 模型,说明通过将周期性突变机制引入 DBO 算法中可增强算法的寻优能力,进一步提升 ARIMA 模型的预测精度。

4 结 论

本文提出一种基于改进蜣螂优化算法的差分整合移动平均自回归预测模型。针对电力变压器振动信号因非平稳、非线性特点而导致难以预测的问题,通过在 DBO 算法中引入周期性突变机制以提升算法的寻优能力,并利用改进的 DBO 算法对 ARIMA 模型参数 p 和 q 进行定阶,进而构建电力变压器振动信号预测模型,解决 ARIMA 模型难以定阶的问题。以 RMSE、MAE、MAPE 和 R^2 为评价指标,并利用某个 0.4~0.4-kV,15-kVA 三相双绕组干式变压器实际采集的振动数据,验证了本文所提出模型的有效性,结果表明, IDBO-ARIMA 模型与

DBO-ARIMA 模型、ARIMA 模型、RNN 网络、LSTM 网络和 CNN 网络相比,具有更高的预测精度。

本文当前的主要工作是利用单一状态信息(振动信息)实现变压器振动信号的预测,然而变压器的振动同时受负载电流、油温等多方面因素的影响,充分考虑多类状态信息对提升变压器振动信号预测精度有着至关重要的作用。因此,本文后续的工作将全面考虑变压器负载电流等影响因素,进一步提升变压器振动信号的预测精度。

参考文献

- [1] FU X Q, ZHOU Y Z. Collaborative optimization of PV greenhouses and clean energy systems in rural areas[J]. IEEE Transactions on Sustainable Energy, 2023, 14(1): 642-656.
- [2] 周亚中, 付学谦, 杨菲菲, 等. 考虑空间耦合的农业园区能源互联网静态安全分析[J]. 电网技术, 2022, 46(3): 995-1004.
ZHOU Y ZH, FU X Q, YANG F F, et al. Static security analysis of park-level agricultural energy internet considering spatial coupling [J]. Power System Technology, 2022, 46(3): 995-1004.
- [3] 付学谦, 周亚中, 孙宏斌, 等. 园区农业能源互联网在线安全分析: 评述与展望[J]. 中国电机工程学报, 2020, 40(17): 5404-5412.
FU X Q, ZHOU Y ZH, SUN H B, et al. Online security analysis of a park-level agricultural energy internet: Review and prospect [J]. Proceedings of the CSEE, 2020, 40(17): 5404-5411.
- [4] 徐耀松, 包力铭, 管智峰, 等. 基于 IPPA 优化 PNN 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2022, 36(10): 138-145.
XU Y S, BAO L M, GUAN ZH F, et al. Research on transformer fault diagnosis based on IPPA optimization PNN [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 138-145.
- [5] 李黄曼, 张勇, 张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(3): 123-129.
LI H M, ZHANG Y, ZHANG Y. Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 123-129.
- [6] 邵凯旋, 何怡刚, 汪磊. 基于多尺度熵分析与改进 SVM 的变压器故障识别[J]. 电子测量与仪器学报, 2022, 36(6): 161-168.
SHAO K X, HE Y G, WANG L. Fault identification of transformer based on multiscale entropy analysis and improved SVM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 161-168.
- [7] LIU D S, LI J C, WANG S H, et al. Detection and analysis of fault for HTS AMDT cores by magnetostriction-induced vibration [J]. IEEE Transactions on Applied Superconductivity, 2019, 29(2): 5500705.
- [8] 李中, 张卫华, 孙娜, 等. 基于广义回归神经网络的变压器表面振动基频幅值计算[J]. 高电压技术, 2017, 43(7): 2287-2293.
LI ZH, ZHANG W H, SUN N, et al. Calculation of vibration fundamental frequency amplitude of transformer surface based on generalized regression neural network [J]. High Voltage Engineering, 2017, 43(7): 2287-2293.
- [9] 胡徐铭. 在运变压器绕组状态振动监测及预测方法研究[D]. 上海: 上海交通大学, 2018.
HU X M. Vibration monitoring and predicting methods of transformer winding in operation [D]. Shanghai: Shanghai Jiao Tong University, 2018.
- [10] ZOLLANVARI A, KUNANBAYEV K, BITAGHSIR S A, et al. Transformer fault prognosis using deep recurrent neural network over vibration signals [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 2502011.
- [11] CHEN Q, LI Z. A transformer vibration amplitude prediction method via fusion of multi-signals [C]. 2021 IEEE 5th Conference on Energy Internet and Energy System Integration (EI2), 2021.
- [12] 赵莉华, 刘浩, 罗小春, 等. 基于 TVFEMD 与中心频率算法的变压器绕组松动故障诊断方法[J]. 电测与仪表, 2020, 57(15): 19-25.
ZHAO L H, LIU H, LUO X CH, et al. Diagnosis method for winding looseness fault of transformer based on TVFEMD and center-frequency [J]. Electrical Measurement & Instrumentation, 2020, 57(15): 19-25.
- [13] 何鑫, 郭敬滨, 吴建宾, 等. 基于时间序列的蒸发波导高度短期预测[J]. 电子测量与仪器学报, 2018, 32(1): 103-110.
HE X, GUO J B, WU J B, et al. Short-term forecast for evaporation duct height based on time series [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 103-110.
- [14] 周文, 孟良, 杨正富, 等. 基于时间序列的大型光伏电站发电短期预测[J]. 电源技术, 2021, 45(11): 1490-1494.
ZHOU W, MENG L, YANG ZH F, et al. Short-term forecasting method of large-scale photovoltaic power station based on time series [J]. Chinese Journal of Power Sources, 2021, 45(11): 1490-1494.
- [15] 王晨, 叶江明, 何嘉弘. 基于不同分布下 GARCH-M

- 族模型的短期用户负荷预测[J]. 电力工程技术, 2022, 41(5): 110-115.
- WANG CH, YE J M, HE J H. Short-term user load forecasting based on GARCH-M family model with different distributions[J]. Electric Power Engineering Technology, 2022, 41(5): 110-115.
- [16] 黄新波, 李弘博, 朱永灿, 等. 基于时间序列分析与卡尔曼滤波的输电线路覆冰短期预测[J]. 高电压技术, 2017, 43(6): 1943-1949.
- HUANG X B, LI H B, ZHU Y C, et al. Short-term forecast for transmission line icing by time series analysis and Kalman filtering[J]. High Voltage Engineering, 2017, 43(6): 1943-1949.
- [17] 黄新波, 蒋卫涛, 朱永灿, 等. 基于时间序列和支持向量机的变压器故障预测[J]. 高电压技术, 2020, 46(7): 2530-2538.
- HUANG X B, JIANG W T, ZHU Y C, et al. Transformer fault prediction based on time series and support vector machine[J]. High Voltage Engineering, 2020, 46(7): 2530-2538.
- [18] 邢致恺, 贾鹤鸣, 宋文龙. 基于莱维飞行樽海鞘群优化算法的多阈值图像分割[J]. 自动化学报, 2021, 47(2): 363-377.
- XING ZH K, JIA H M, SONG W L. Levy flight trajectory-based salp swarm algorithm for multilevel thresholding image segmentation[J]. Acta Automatica Sinica, 2021, 47(2): 363-377.
- [19] 尚雪梅, 徐远纲. PSO 优化的最大峭度熵反褶积齿轮箱故障诊断[J]. 电子测量与仪器学报, 2020, 34(7): 64-72.
- SHANG X M, XU Y G. Maximum kurtosis entropy deconvolution gearbox fault diagnosis based on PSO[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(7): 64-72.
- [20] 肖剑, 张凯, 高凡, 等. 基于改进 HHO 算法的螺纹钢丝头中径测量方法[J]. 电子测量与仪器学报, 2021, 35(10): 48-55.
- XIAO J, ZHANG K, GAO F, et al. Pitch diameter measurement of threaded steel wire head based on improved HHO algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 48-55.
- [21] 王立宪, 马宏忠, 戴锋. 基于机电联合的 GIL 局部放电趋势预测研究[J]. 电子测量与仪器学报, 2021, 35(10): 98-106.
- WANG L X, MA H ZH, DAI F. Research on partial discharge trend prediction of GIL based on WOA-ELM[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 98-106.
- [22] XUE J K, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [23] YAN C, ZHANG Y K, ZHONG W Y, et al. A truncated SVD-based ARIMA model for multiple QoS prediction in mobile edge computing[J]. Tsinghua Science and Technology, 2022, 27(2): 315-324.
- [24] 曹俊波, 周任军, 邓学华, 等. 考虑优化 ARIMA 模型差分次数的风功率预测[J]. 电力系统及其自动化学报, 2019, 31(1): 105-111.
- CAO J B, ZHOU R J, DENG X H, et al. Wind power forecast considering differential times of optimal ARIMA model[J]. Proceedings of the CSU-EPSC, 2019, 31(1): 105-111.
- [25] SHAO K X, FU W L, TAN J W, et al. Coordinated approach fusing time-shift multiscale dispersion entropy and vibrational Harris hawks optimization-based SVM for fault diagnosis of rolling bearing[J]. Measurement, 2021, 173: 108580.

作者简介



周亚中, 2022 年于中国农业大学获得硕士学位, 现为武汉大学电气与自动化学院博士研究生, 主要研究方向为变压器故障诊断与预测、农业能源互联网安全经济运行理论研究。

E-mail: zhou_yazhong@whu.edu.cn

Zhou Yazhong received the M. Sc. degree from China Agricultural University in 2022. Now he is now a Ph. D. candidate at Wuhan University. His main research interests include transformer fault diagnosis and prediction, theoretical research on safe and economic operation of agricultural energy internet.



何怡刚 (通信作者), 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现为武汉大学二级教授, 国家杰出青年基金获得者, 主要研究方向为能源装备状态监测、电力电子电路理论及其应用等。

E-mail: yghe1221@whu.edu.cn

He Yigang (Corresponding author) received the M. Sc. degree from Hunan University, Changsha, China, in 1992, and the Ph. D. degree from Xian Jiaotong University, Xian, China, in 1996. He is now a second level professor at Wuhan University and a winner of the national science fund for distinguished young scholars. His main research interests include condition monitoring of energy equipment, power electronic circuit theory and its applications, etc.