

基于 IPOA-BP 的输电塔复合基础极限抗拔承载力 预测模型^{*}

杨世强¹ 李小来¹ 王彦海² 曹 铖¹ 马 立¹ 尹恒伟²

(1. 国网湖北省电力有限公司超高压公司 武汉 430051;

2. 三峡大学电气与新能源学院 宜昌 443002)

摘 要:为了实现输电塔复合基础极限抗拔承载力的准确预测,克服传统理论、经验公式误差大,计算慢的问题,提出一种改进鹈鹕智能算法(IPOA)来优化 BP 神经网络的承载力预测模型。首先,利用 SPM 混沌映射、Levy 飞行以及融合非线性惯性权重因子 ω 的正余弦优化策略,对鹈鹕优化算法(POA)改进;然后,利用 IPOA 对 BP 神经网络的权值和阈值参数寻优,得到 IPOA-BP 预测模型;最后,基于验证后的数值试验构建数据集,对 IPOA-BP 预测模型进行训练和测试。结果表明,IPOA-BP 与 POA-BP 预测模型相比,方根误差下降 65.75%,绝对平均误差下降 65.79%,平均相对误差下降 65.60%,可见 IPOA-BP 神经网络能够实现复合基础抗拔承载力较准确的预测,为该类型基础的承载力预测提供了新方法。

关键词:改进鹈鹕优化算法;复合基础;BP 神经网络;SPM 混沌映射;正余弦优化策略

中图分类号: TP183;TU391 **文献标识码:**A **国家标准学科分类代码:** 520.2060

Prediction model of ultimate pullout capacity of transmission tower composite foundation based on IPOA-BP

Yang Shiqiang¹ Li Xiaolai¹ Wang Yanhai² Cao Cheng¹ Ma Li¹ Yin Hengwei²

(1. EHV Company of State Grid Hubei Electric Power Co., Ltd., Wuhan 430051, China;

2. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: In order to achieve accurate prediction of the ultimate elevation bearing capacity of the composite foundation of transmission towers and overcome the problems of large error and slow calculation of the theoretical or traditional empirical formulas, an improved pelican intelligent algorithm (IPOA) is proposed to optimize the bearing capacity prediction model of the BP neural network. Firstly, the pelican optimization algorithm (POA) is optimized using SPM chaotic mapping, Levy flight, and a positive cosine optimization strategy that incorporates nonlinear inertial weight factor ω . Then, the optimized IPOA is used to find the optimization of the weight and threshold parameters of the BP neural network, and the IPOA-BP prediction model is obtained; finally, a dataset is constructed based on validated simulation experiments and the IPOA-BP prediction model is trained and tested. The results show that compare with the POA-BP prediction model, the square root error of IPOA-BP decreases by 65.75%, the absolute average error decreases by 65.79%, and the average relative error decreases by 65.60%, it can be seen that IPOA-BP neural network can achieve a more accurate prediction of the composite foundation's resistance to elevation bearing capacity, which provides a new method for the prediction of the bearing capacity of this type of foundation.

Keywords: improved pelican optimization algorithm; composite foundation; BP neural network; SPM chaotic mapping; positive cosine optimization strategy

收稿日期:2023-10-08

^{*} 基金项目:国家自然科学基金(U22A20600,52079070)项目资助

0 引言

随着“西电东送”国家战略的实施,输电线路途经土岩复合地层越发频繁,新型输电铁塔基础应运而生^[1-2]。短桩—锚杆复合基础作为其中的典型代表,通过在上覆土层中应用挖孔短桩,在下卧硬岩中补充岩石群斜锚,使得复合基础充分发挥了两种地层的天然力学特性,极大地提升了其抗拔承载力^[3]。然而,短桩—斜锚复合基础非单一形式基础,当前规范^[4-5]无法确定上下两种基础形式的承载力发挥系数 k (仍需选用经验值),仅给出其抗拔承载力计算经验公式,故众多学者围绕各影响因素与承载力间的关系展开研究。孙义舟等^[6]分析了上拔荷载与位移关系的相关解析解,提出了桩—锚复合基础的抗拔承载力发挥系数 k 的理论计算公式,使得基础承载力得以量化。王彦海等^[7]考虑了岩层中锚杆角度对承载力的影响,提出短桩—斜锚复合基础的极限承载力计算公式,计算结果与试验值误差介于±12%。但由于复合基础众多影响因素与承载力间呈现出非线性的映射关系,使得采用理论、经验公式计算出的短桩—斜锚复合基础极限抗拔承载力与试验值存在较大误差,适应性差。

近年来,机器学习算法迅速发展,其中反向传播(back propagation, BP)神经网络因其强大的计算和泛化能力,可实现对任意复杂度函数的非线性拟合,应用于桩基承载力预测等工程领域^[8]。渠建伟^[9]基于BP神经网络对振冲碎石桩复合地基承载力进行快速预测,实现了工程实时检测的需求。蒋建平^[10]利用BP神经网络对横向受荷桩的承载力进行预测,结果表明承载力误差较小,预测模型可行。王昆明等^[11]采用BP神经网络建立了高应变动力测试法与静荷载试验间的内在联系,较准确地实现了嵌岩桩竖向承载力的预测。但BP神经网络的权值调整空间存在平坦区和局部最优值,导致其有着收敛速度慢、易陷于局部极小而达不到全局最优的问题^[12]。鹈鹕优化算法(pelican optimization algorithm, POA)是一种依据鹈鹕的捕食行为所提出的随机自然启发优化算法,相较于其他优化算法,其在探索和开发之间实现了比例平衡,具有良好的全局寻优性能^[13]。

鉴于上述问题和原因,本文将复合基础极限抗拔承载力试验数据与智能算法相结合,提出一种考虑6种影响因素,基于改进鹈鹕优化算法(IPOA)优化BP神经网络的复合基础极限抗拔承载力预测模型。首先采用SPM复合混沌映射初始化鹈鹕种群,增强其种群位置的遍历性;利用Levy飞行策略对勘探阶段的POA算法进行优化,进一步增强其全局搜索能力;再利用正余弦优化策略,加强算法的局部开发能力,丰富种群的多样性,提高其求解速度和精度;最后将改进后的IPOA正向优化BP神经网络的权值和阈值,建立IPOA-BP神经网络模型。利用ABAQUS建立包含复合基础、土体和岩体的合理整体有限元模型,得到考虑6因素的复合基础极限抗拔承载力数据集。最

终将复合基础极限抗拔承载力数据集用于IPOA-BP神经网络预测模型的训练和测试,实现对输电塔复合基础承载力的可靠预测。

1 POA

POA是Pavel等^[13]依据鹈鹕狩猎过程中扑向猎物、在水面上扇动翅膀等自然行为,于2022年提出的一种新型群体智能优化算法。

1.1 种群随机初始化

通常来说,数量为 n 、求解维度为 m 的鹈鹕种群可用矩阵 X 表示:

$$X = \begin{bmatrix} X_1 \\ \vdots \\ X_i \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,m} \\ \vdots & & \vdots & & \vdots \\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,m} \\ \vdots & & \vdots & & \vdots \\ x_{n,1} & \cdots & x_{n,j} & \cdots & x_{n,m} \end{bmatrix}_{n \times m} \quad (1)$$

式中: X_i 为第 i 只鹈鹕的个体位置,代表了求解空间中的每一个候选解; $x_{i,j}$ 表示第 i 只鹈鹕所在 j 维的位置。

对种群内部每只鹈鹕所在位置 $x_{i,j}$ 进行随机初始化的过程:

$$x_{i,j} = l_j + rand \cdot (u_j - l_j) \quad (2)$$

式中: $i=1,2,\dots,n$; $j=1,2,\dots,m$; $rand$ 为 $[0,1]$ 的随机数; u_j 和 l_j 分别是所需优化种群维度 j 的上、下边界。

在POA中,每只鹈鹕都可看做所求问题的候选解,因此,可以根据每个候选解来评估给定问题的目标函数,表达式如下:

$$F = \begin{bmatrix} F_1 \\ \vdots \\ F_i \\ \vdots \\ F_n \end{bmatrix}_{n \times 1} = \begin{bmatrix} F(X_1) \\ \vdots \\ F(X_i) \\ \vdots \\ F(X_n) \end{bmatrix}_{n \times 1} \quad (3)$$

式中: F 为目标函数向量, F_i 为第 i 个鹈鹕候选解的目标函数值。

1.2 逼近猎物(勘探阶段)

在勘察阶段,鹈鹕扩大觅食视野进而确定猎物的位置,然后朝这个区域移动,该阶段鹈鹕的位置更新方式如下:

$$x_{i,j}^{p_{KT}} = \begin{cases} x_{i,j} + rand \cdot (p_j - I \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} + rand \cdot (x_{i,j} - p_j), & \text{其他} \end{cases} \quad (4)$$

式中: $x_{i,j}^{p_{KT}}$ 为勘探阶段中第 i 只鹈鹕在第 j 维的位置; p_j 为鹈鹕猎物第 j 维的位置; I 是取值为1或2的随机整数; F_p 为鹈鹕猎物的目标函数值; F_i 为第 i 只鹈鹕的目标函数值。

勘探阶段结束时,需要将得到改善的鹈鹕目标函数值 F_i 进行位置更新,同时避免算法被移动到非最优区域,其数学模型为:

$$X_i = \begin{cases} X_i^{PKT}, & F_i^{PKT} < F_i \\ X_i, & \text{其他} \end{cases} \quad (5)$$

式中: X_i^{PKT} 为勘探阶段第 i 只鹈鹕的新位置; F_i^{PKT} 为第 i 只鹈鹕新位置目标函数值。

1.3 水面飞行(开发阶段)

在开发阶段,鹈鹕用翅膀扑打水面,从而迫使鱼游入浅水区,然后把将尽可能多猎物舀到它们的喉囊里,为模拟这种收缩行为,引入系数 $R \cdot (1-t/t_{\max})$ 对鹈鹕的捕猎行为进行选择,取值范围为 $(0, 0.2)$; 该阶段鹈鹕的位置更新方式如下:

$$x_{i,j}^{PKF} = x_{i,j} + R \cdot (1-t/t_{\max}) \cdot (2 \cdot rand - 1) \cdot x_{i,j} \quad (6)$$

式中: $x_{i,j}^{PKF}$ 为开发阶段中第 i 只鹈鹕在第 j 维的位置; R 是常数 0.2 ; t 为当前迭代次数; t_{\max} 为设定的最大迭代次数。

与勘探阶段类似,若鹈鹕新位置的目标函数值较小,需进行位置的有效更新,更新公式为:

$$X_i = \begin{cases} X_i^{PKF}, & F_i^{PKF} < F_i \\ X_i, & \text{其他} \end{cases} \quad (7)$$

式中: X_i^{PKF} 为开发阶段第 i 只鹈鹕的新位置; F_i^{PKF} 为第 i 只鹈鹕新位置目标函数值。

2 IPOA

为进一步提高 POA 在初始化种群分布的均匀性、全局搜索能力和局部开发时的寻优能力。采用 SPM 混沌映射、Levy 飞行和正余弦优化 3 种策略,对 POA 进行正向优化,提出 IPOA。

2.1 SPM 混沌映射

POA 的种群初始化依旧使用的是传统的伪随机数方法,生成的鹈鹕个体存在较大随机性,易出现鹈鹕初始化种群位置聚集现象,限制了算法的全局搜索能力。利用混沌映射初始化种群可以使得鹈鹕初始化种群位置具有较强的遍历性,从而提高算法的全局寻优能力。

SPM 混沌映射是一种高效的一维复合混沌映射,其融合了 Sine 映射和 PWLCM 映射^[14]。相较于 Tent、Logistic 等单一混沌映射,更具有混沌特性,有着空间遍历性好,种群多样性丰富,相平面内分布均匀,结构简单、效率高的优点。

因此,本文选取 SPM 混沌映射作为改进鹈鹕优化算法的初始化方法。SPM 混沌公式如下:

$$X_{i+1} = \begin{cases} \text{bmod}(X_i/\eta + \mu \sin(\pi X_i) + r, 1), & 0 \leq X_i < \eta \\ \text{bmod}(X_i/\eta + \mu \sin(\pi X_i) + r, 1), & \eta \leq X_i < 0.5 \\ F(1 - X_{i-1}, \eta, \mu), & 0.5 \leq X_i < 1 \end{cases} \quad (8)$$

式中:控制参数 $\eta, \mu \in (0, 1)$ 时,系统处于混沌状态;扰动参数 r 为 $(0, 1)$ 的随机数; X_i 为第 i 个 SPM 混沌映射序列。

2.2 Levy 飞行策略

Levy 飞行策略是由法国数学家提出的一种基于 Levy 分布的随机游走策略,具有长时间以较小步长随机游走,偶尔以较大步长进行方向突变跳跃飞行特点,与智能优化算法中的开发和勘探阶段的搜索特征相似^[15-16]。因此,可在 POA 的勘探阶段,利用 Levy 飞行策略,给当前最优鹈鹕个体位置施加一个随机步长的扰动量,进行一次额外的小范围搜索,从而增强 POA 算法的全局搜索能力,以避免陷入局部最优解。其数学模型可表示为:

$$x_{i,j}^{PKT} = \begin{cases} x_{i,j} \cdot \alpha \oplus Levy(\lambda) + rand \cdot (p_j - I \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} \cdot \alpha \oplus Levy(\lambda) + rand \cdot (x_{i,j} - p_j), & \text{其他} \end{cases} \quad (9)$$

式中:步长尺度系数 $\alpha = 0.01$; \oplus 为内积运算符号; $Levy(\lambda)$ 为随机游走步长。

$$Levy(\lambda) = s = u / |v|^{1/\beta} \quad (10)$$

$$\begin{cases} \sigma_u = \left[\frac{\Gamma(1+\beta) \cdot \sin(\beta/2 \cdot \pi)}{\Gamma((1+\beta)/2) \cdot \beta \cdot 2^{(\beta-1)/2}} \right]^{1/\beta} \\ \sigma_v = 1 \end{cases} \quad (11)$$

式中:指数参数 $\beta \in (0, 2)$; u 和 v 为符合正态分布随机数; $u \sim N(0, \sigma_u^2)$, $v \sim N(0, \sigma_v^2)$; $\Gamma(x)$ 为 Gamma 函数。

2.3 正余弦优化策略

在 POA 的寻优阶段,随着迭代次数增加,算法局部开发能力减弱,种群多样性变差,仅仅采用线性随机的位置更新策略,难以实现对当前最优解的深度发掘,导致求解精度较低^[17]。而正余弦算法可利用正弦余弦函数的震荡性来维持算法迭代后期种群多样性,加强算法的局部开发能力^[18-19]。因此,在鹈鹕算法的开发阶段式(6),引入正余弦算法和非线性惯性权重因子 ω ,式(6)修正后的表达式如下:

$$x_{i,j}^{PKF}(t+1) = \begin{cases} \omega \cdot x_{i,j}(t) + R \cdot (1-t/t_{\max}) \cdot x_{i,j}(t) \cdot [2 \cdot r_1 \sin(r_2) | x_{i,j}^{best} - x_{i,j}(t) | - 1], & r_4 < 0.5 \\ \omega \cdot x_{i,j}(t) + R \cdot (1-t/t_{\max}) \cdot x_{i,j}(t) \cdot [2 \cdot r_1 \sin(r_2) | x_{i,j}^{best} - x_{i,j}(t) | - 1], & r_4 \geq 0.5 \end{cases} \quad (12)$$

式中: $x_{i,j}^{PKF}(t+1), x_{i,j}(t)$ 为开发阶段第 $t+1, t$ 次迭代时第 i 只鹈鹕在第 j 维的位置; $x_{i,j}^{best}$ 当前最优个体; r_2, r_3 分别为区间 $(0, 2\pi)$ 和 $(0, 2)$ 服从均匀分布的数;正余弦函数选择控制因子 $r_4 \in (0, 1)$ 。

r_1 决定算法的局部探索和全局搜索能力,随迭代次数动态变化,表达式为:

$$r_1 = a - a \frac{t}{t_{\max}} \quad (13)$$

式中: a 为大于 1 的常数,常取经验值 2。

非线性惯性权重因子 ω 可进一步平衡 POA 算法的勘探和开发能力,其计算公式如下:

$$\omega = -\frac{\pi}{2} \cdot \arctan(t) + \exp\left(-\frac{t}{m}\right) + 1 \quad (14)$$

3 IPOA 算法性能评价

3.1 仿真实验环境

为保证实验的公正性,本文所有仿真测试均为同一环境,Windows 11 操作系统,CPU 为 11th Gen Intel(R) Core(TM) i7-11800H,主频 2.3 GHz, RAM 为 16.0 GB,仿真软件为 MATLAB 2022b。

3.2 实验的初始参数设置

为测试改进鹈鹕算法的寻优性能,选取 CEC2005^[20]

上的 6 个标准测试函数进行实验验证,表 1 为标准测试函数的函数名、表达式、维度、搜索空间和理论最优解。6 个标准测试函数中, $f_1 \sim f_2$ 是连续单峰函数,只有一个全局最优解,用于检验算法的收敛速度和开发能力; $f_3 \sim f_6$ 是复杂多峰函数,有较多局部极值点,主要用于检验算法跳出局部最优和探索能力。另设 POA^[13]、鲸鱼优化算法 (whale optimization algorithm, WOA)^[21]、灰狼优化算法 (grey wolf optimizer, GWO)^[22] 与 IPOA 进行标准函数对比。各算法参数设置为 IPOA、POA 中 I 取值 1, R 取 0.2; WOA 中 $a_1 = [2, 0], a_2 = [-2, -1], b = 1$; GWO 中参数 a 从 2 线性递减至 0, $r_1, r_2 \in [0, 1]$ 。各算法种群规模为 30, 最大迭代次数为 500, 所有算法均独立运行 30 次。

表 1 标准测试函数

Table 1 Standard test functions

函数名	表达式	维度	搜索空间	f_{\min}
Schwefel 2.22	$f_1(x) = \sum_{i=1}^d x_i + \prod_{i=1}^d x_i $	30	$[-10, 10]$	0
Schwefel 1.2	$f_2(x) = \sum_{i=1}^d \left(\sum_{j=1}^d x_j\right)^2$	30	$[-100, 100]$	0
Rastrigin	$f_3(x) = \sum_{i=1}^d [x_i^2 - 10\cos(2\pi x_i)] + 10d$	30	$[-5.12, 5.12]$	0
Griewank	$f_4(x) = \frac{1}{4000} \sum_{i=1}^d x_i^2 - \prod_{i=1}^d \cos \frac{x_i}{\sqrt{i}} + 1$	30	$[-600, 600]$	0
Bohachevsky	$f_5(x) = \sum_{i=1}^{d-1} \left[0.5 + \frac{\sin^2(\sqrt{100x_i^2 + x_{i+1}^2}) - 0.5}{1 + 0.001(x_i^2 - 2x_i x_{i+1} + x_{i+1}^2)^2} \right]$	30	$[-100, 100]$	0
Schaffter	$f_6(x) = 0.5 + \frac{\sin^2\left(\sqrt{\sum_{i=1}^d x_i^2}\right) - 0.5}{1 + 0.001 \sum_{i=1}^d x_i^2}$	30	$[-100, 100]$	0

3.3 结果分析

采用 IPOA 算法对 6 个标准测试函数进行求解,并与 POA、WOA 和 GWO 算法的性能进行比较,通过统计 4 种算法的最差值、最优值、平均值和标准差等性能指标来评价算法的性能,并对其算法性能进行排序,具体结果如表 2 所示,其中粗体部分表示寻优结果最好的算法。

由表 2 可知,对于连续单峰函数(f_1, f_2)和复杂多峰函数($f_3 \sim f_6$),IPOA 算法 30 次独立实验的平均值均能收敛至 0,排名第 1,寻优能力明显优于 POA、WOA、GWO;此外,IPOA 的 6 个基准测试函数标准差都非常小,说明其具有很强的鲁棒性。与 POA 相比,除 f_3 和 f_4 函数测试结果相同,IPOA 算法在 f_5 和 f_6 函数测试结果的最优值、平均值和标准差均最优,跳出了局部最优解,未随函数复杂度升高而下降,有着较强的稳定性。

总体来说,IPOA 相较于 POA 有着明显优势,说明本文所用 Levy 飞行和正余弦优化改进策略是有效的。4 种算法在 6 个基准测试函数的收敛曲线如图 1 所示。

从图 1(a)~(f)可以看出,IPOA 达到稳定所需的迭代次数远小于其他 3 种算法,能够在较少的迭代次数下便可收敛至理论最优值,且收敛精度较高。这是因为在 IPOA 算法中引入的 Levy 飞行策略和非线性惯性权重因子 ω ,为鹈鹕狩猎过程起到了良好的方向引导作用,减少了不必要的搜索,平衡了算法的全局搜索能力和局部搜索能力,提升了算法的精度。

4 IPOA 优化 BP 预测模型

BP 神经网络是一种误差反向传播算法训练的多层前馈网络,它的基本思想是利用梯度搜索技术,以期使网络的实际输出值和期望输出值的误差均方差为最小,包含信

表 2 4种算法性能对比
Table 2 Performance comparison of four algorithms

函数	算法	最差值	最优值	平均值	标准差	排名
$f_1(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	1.02×10^{-50}	1.02×10^{-50}	4.33×10^{-52}	4.32×10^{-52}	2
	WOA	1.95×10^{-49}	1.99×10^{-57}	7.35×10^{-51}	3.55×10^{-50}	3
	GWO	2.07×10^{-16}	1.79×10^{-17}	9.43×10^{-17}	5.48×10^{-17}	4
$f_2(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	1.92×10^{-97}	2.97×10^{-116}	6.59×10^{-99}	3.51×10^{-98}	2
	WOA	8.84×10^4	2.34×10^4	4.50×10^4	1.56×10^4	4
	GWO	0.00	1.32×10^{-8}	7.24×10^{-6}	2.22×10^{-5}	3
$f_3(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	0.00	0.00	0.00	0.00	1
	WOA	5.68×10^{-14}	0.00	1.89×10^{-15}	1.04×10^{-14}	2
	GWO	18.88	5.68×10^{-14}	2.77	4.88	3
$f_4(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	0.00	0.00	0.00	0.00	1
	WOA	0.18	0.00	0.01	0.04	3
	GWO	0.03	0.00	0.00	0.01	2
$f_5(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	3.27	6.92×10^{-11}	1.09	1.08	3
	WOA	1.00	9.56×10^{-12}	0.07	0.22	2
	GWO	12.09	9.15	11.01	0.67	4
$f_6(x)$	IPOA	0.00	0.00	0.00	0.00	1
	POA	0.01	0.00	0.01	0.00	2
	WOA	0.04	0.00	0.02	0.02	3
	GWO	0.08	0.01	0.03	0.01	4

号的前向传播和误差的反向传播两个过程^[23]。其中,权值和阈值的选择是误差反向传播的核心,对后续样本预测产生较大影响,因此,本文采用 IPOA 模型对 BP 神经网络中权值和阈值进行优化,用于预测复合基础的极限承载力,流程如图 2 所示。

1) 预处理样本数据。将数据集划分为训练集与测试集,两者比例设定为 5:1,并将其归一化至[0,1],提高训练效率。

2) 设置 BP 神经网络。选定 BP 神经网络输入层、隐藏层和输出层节点数量,确定网络的拓扑结构。

3) POA 优化算法初始化。根据鸚鵡捕食行为的特点,随机初始化鸚鵡种群,初始种群数量为 30,最大迭代次数设置为 500,并将 BP 神经网络的预测均方误差作为 POA 算法的适应度函数,适应度值越小表示误差越小。

4) 利用 SPM 混沌映射初始化种群,引入 Levy 飞行策略扩大鸚鵡勘探阶段全局搜索范围,引入正余弦策略和非

线性权重因子增强局部寻优能力,建立 IPOA 模型。

5) 利用式(4)和(5)动态更新鸚鵡个体位置,并将完成更新的适应度值与已有的最优适应度值进行比较,判断是否达到预设的收敛精度或最大迭代次数,进行选择全局最优解。

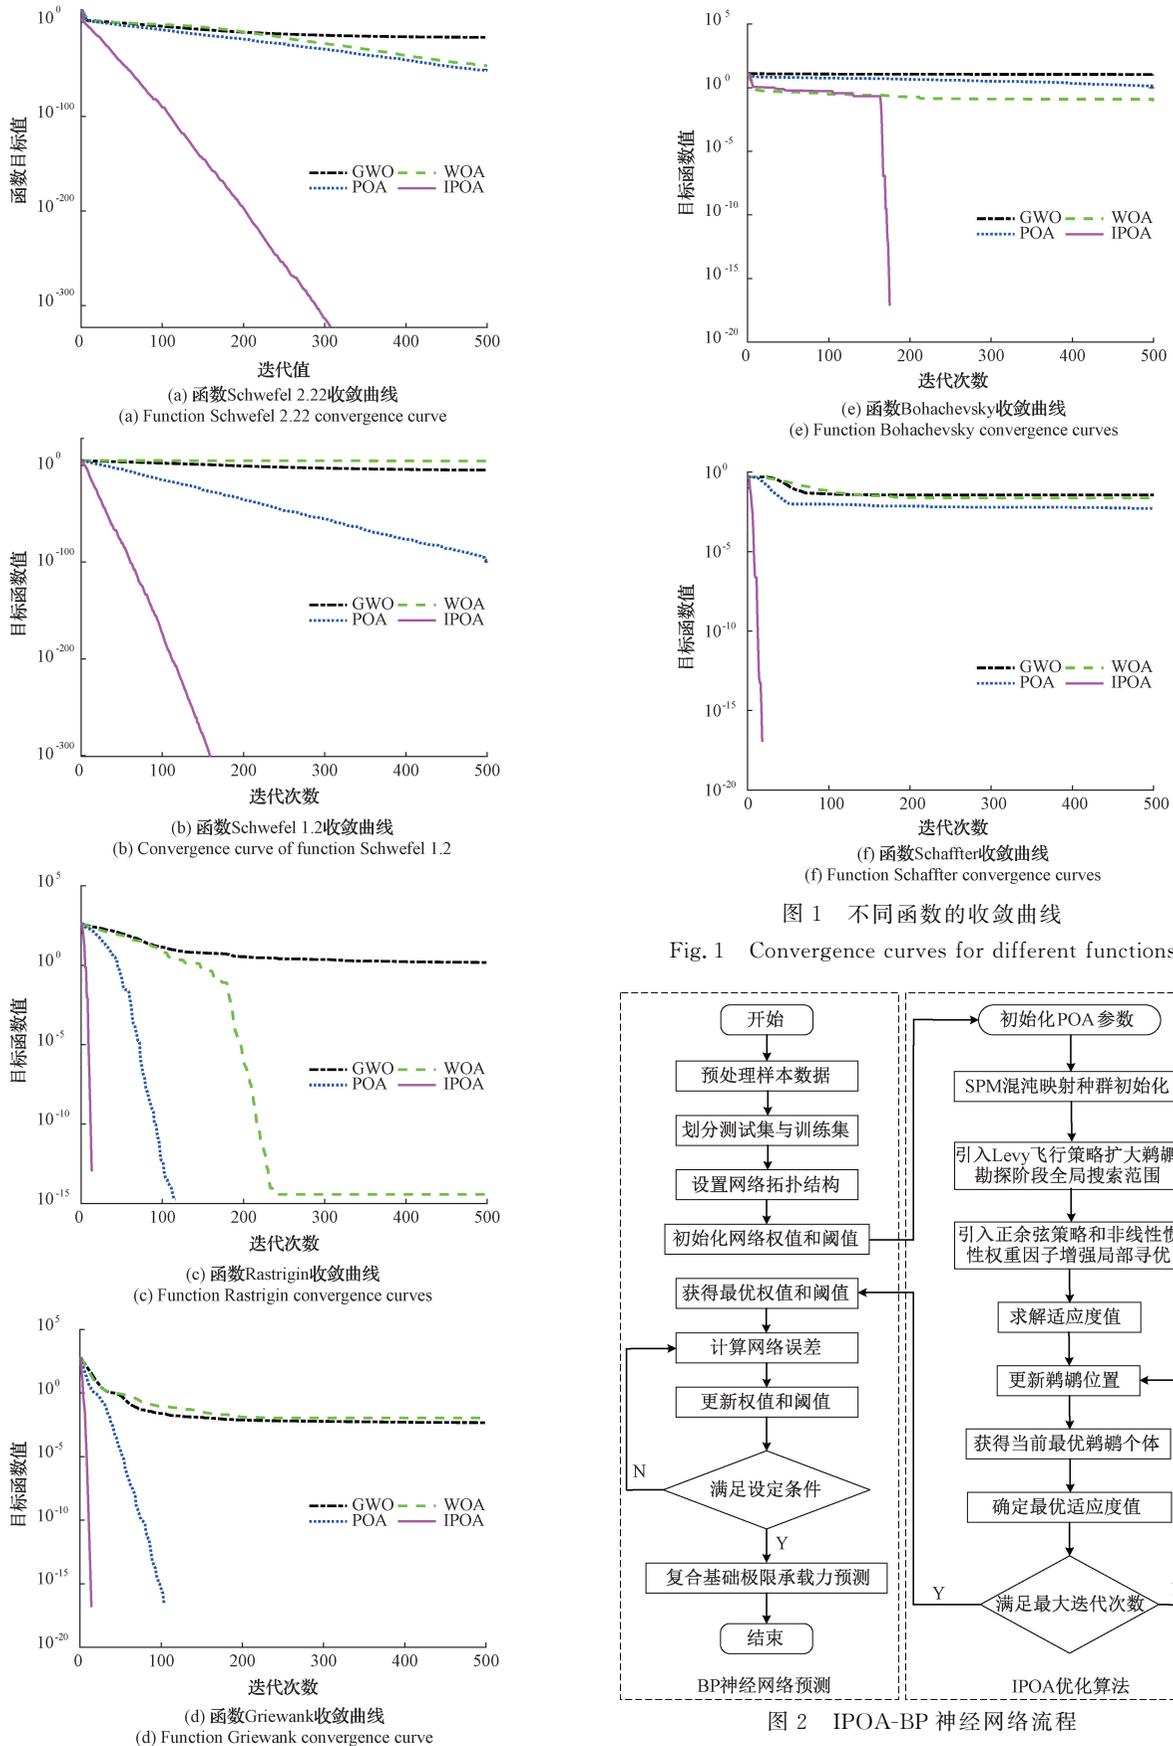
6) 将步骤 5) 中 IPOA 模型求解得到的最优解赋值替代 BP 神经网络中的权值和阈值,再根据 BP 神经网络的误差反向传播机制微调参数,当误差满足提前设定的精度或者达到最大迭代次数时结束训练。

7) 运用训练好的 IPOA-BP 神经网络预测模型,用于预测短桩-斜锚复合基础极限抗拔承载力。

5 实例分析

5.1 建立典型复合基础模型

首先,根据文献[3]中 FH1-6 复合基础现场试验参数及结果,运用 ABAQUS 对其进行建模计算,验证复合基础数值试验方法的合理性,数值试验结果如图 3 所示。



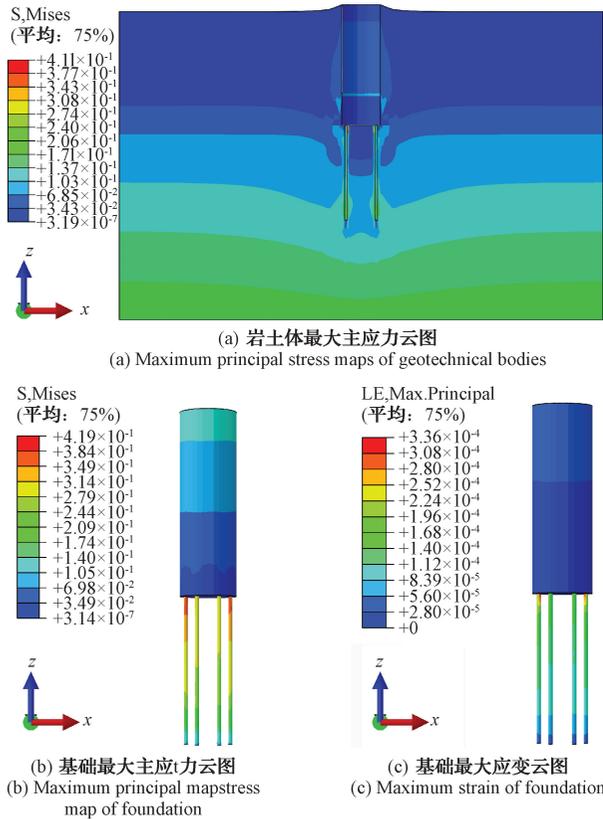


图3 FH1-6 数值试验结果
Fig. 3 FH1-6 numerical test results

从图3(a)可以看出,短桩周围的土体隆起,与文献[3]物理试验中地表土体出现放射状贯通裂缝一致;图3(b)和(c)中,下部直锚的应力、应变大于上部短桩,同样与文献[3]物理试验中直锚复合基础 FH1-6 以锚杆拉伸变形

表3 数值模拟计算参数

Table 3 Calculated parameters for numerical simulation

材料	弹性模量 E/MPa	泊松比 ν	密度 $\rho/(\text{g}\cdot\text{cm}^{-3})$	黏聚力 c/MPa	内摩擦角 $\varphi/(\text{°})$
粉质黏土	10	0.35	1.9	0.016	24
微风化石灰岩	450	0.23	2.4	0.7	53
基础	30 000	0.2	2.5	—	—

5.2 建立数据集

试验基础位于广东省阳春市,依据工程经验,6种影响因素及取值分别为锚杆数量(4、6、8根)、短桩埋深(4.8 m)、短桩直径(1.6、1.8 m)、嵌岩深度(0.0、0.2、0.6 m)、锚杆长度(2.0、3.0、3.5、4.0、4.5 m)和锚杆倾角(0° 、 5° 、 10° 、 15°),共建立 360 组短桩—斜锚复合基础有限元模型,计算出复合基础极限抗拔承载力,构建数据集,部分数据如表 4 所示。

5.3 IPOA-BP 复合基础承载力预测过程

1) 数据集预处理

为了消除各数据间不同量纲的影响,采用 Mapmin-

为主的结论一致。对比 FH1-6 的数值试验与现场试验的极限抗拔承载力分别为 1 832 和 1 800 kN,误差值不超过 1.7%,说明采用本文建立的有限元模型模拟复合基础的上拔受荷行为具有可行性。

在此基础上,建立考虑 6 种影响因素的短桩—斜锚典型复合基础模型,如图 4 所示。

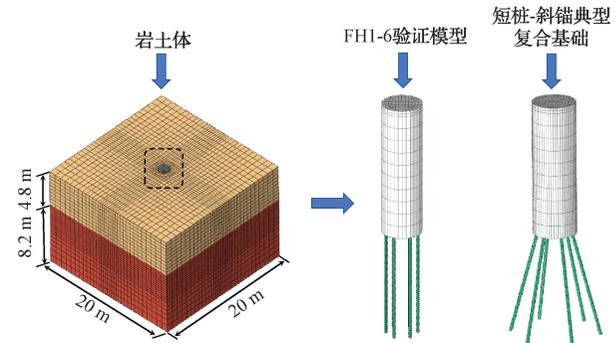


图4 典型复合基础模型
Fig. 4 Typical composite foundation model

图4中岩土体模型尺寸为 $20\text{ m}\times 20\text{ m}\times 13\text{ m}$,复合基础和岩土体采用六面体 C3D8 实体单元模拟,岩土体边界条件为侧面水平约束、底部固定约束、上部自由面;短桩与土体之间采用 Penalty 法模拟,依据土体的综合特性参数,切向摩擦系数 0.8,法向硬接触;锚杆与岩体之间采用随压力变化摩擦系数来等效模拟,压力设置 250 kPa,摩擦系数 $4.8^{[7]}$ 。

考虑复合基础与土体、岩体间的界面强度折减,强度折减系数 R_{int} 分别为 0.5 和 1.0,数值模拟计算地质参数取值如表 3 所示。

max 函数对模型输入输出数据进行归一化处理:

$$X_1 = \frac{X_x - X_{\min}}{X_{\max} - X_{\min}}, \quad X_1 \in [0, 1] \quad (15)$$

式中: X_1 为各特征数据归一化后的值; X_x 为各特征数据原始值; X_{\max} 和 X_{\min} 分别为各特征值的最大、最小值。

将归一化的 360 组极限抗拔承载力数据集,按 5 : 1 比例划分为 300 组训练集(Train)和 60 组测试集(Test)。

2) 网络结构设计

承载力预测模型具有 6 个输入量(锚杆数量、短桩埋深、短桩直径、嵌岩深度、锚杆长度和锚杆倾角),1 个输出量(复合基础极限抗拔承载力)。由此可确定本文 IPOA-

表4 复合基础极限抗拔承载力数据

Table 4 Composite foundation ultimate pullout bearing capacity data

序号	锚杆数量/根	短桩直径/m	短桩埋深/m	嵌岩深度/m	锚杆长度/m	锚杆倾角/(°)	极限抗拔承载力/kN
1	4	1.6	4.8	0.0	2.0	0	1 494.23
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
40	6	1.6	4.8	0.0	4.5	15	2 783.73
41	8	1.6	4.8	0.0	2.0	0	1 600.51
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
80	4	1.6	4.8	0.2	4.5	10	2 764.09
81	6	1.6	4.8	0.2	2.0	15	1 650.06
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
120	8	1.6	4.8	0.2	4.5	15	3 004.43
121	4	1.6	4.8	0.2	2.0	0	1 792.83
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
160	6	1.6	4.8	0.6	4.5	15	3 085.32
161	8	1.6	4.8	0.6	2.0	0	1 906.41
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
200	4	1.8	4.8	0.0	4.5	15	2 754.04
201	6	1.8	4.8	0.0	2.0	0	1 640.00
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
240	8	1.8	4.8	0.0	4.5	15	2 994.37
241	4	1.8	4.8	0.2	2.0	0	1 697.81
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
280	6	1.8	4.8	0.2	4.5	15	2 987.30
281	8	1.8	4.8	0.2	2.0	0	1 808.39
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
320	4	1.8	4.8	0.6	3.0	10	2 309.32
321	4	1.8	4.8	0.6	4.0	0	2 317.56
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
360	8	1.8	4.8	0.6	4.5	15	3 333.67

BP神经网络的输入层节点数为6个,输出层节点数为1个,故神经网络结构的确定主要在于隐含层的节点数。

目前,隐含层节点数的确定还没有确切标准,本文采用“试凑法”,利用式(16)对其进行确定^[24]。

$$m = \sqrt{d+l} + \alpha, \quad \alpha \in [1,10] \quad (16)$$

式中: m 为隐含层节点数; d 为输入层节点数; l 为输出层节点数,故隐含层节点数在3~12,根据误差最小原则确定隐藏层节点数为6。

最终,得到IPOA-BP复合基础抗拔承载力预测模型的结构,如图5所示。

3)模型训练

进行IPOA-BP神经网络的训练前,首先对传统BP神经网络进行初始化,对其进行复合基础承载力的原始预测,用于发现改进分析点和后期预测误差对比分析;随后对3种改进策略优化后的IPOA进行网络参数设置以及种群初始化,用于寻找BP神经网络的最优阈值和权值;最后再对优化后的BP神经网络进行复合基础极限抗拔

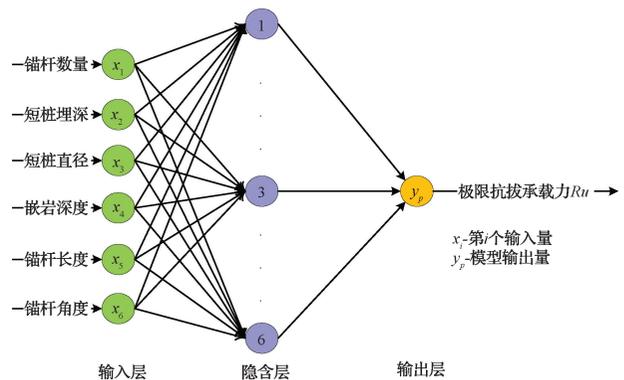


图5 BP神经网络结构

Fig. 5 Structure of BP neural network

承载力的训练。

本文运用MATLAB软件对表4归一化后的300组训练集进行学习。训练中,使用ReLU作为激活函数,最大训练次数为1 000次,训练精度 10^{-5} ,学习率设置为

0.01, 最小性能梯度 10^{-6} , 最高失败 6 次。训练集预测结果如图 6 所示。

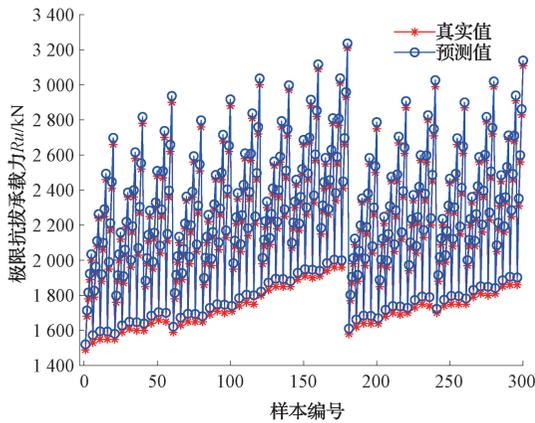


图 6 复合基础极限承载力训练集预测结果

Fig. 6 Prediction results of composite foundation ultimate bearing capacity training set

由图 6 可以看出, IPOA-BP 神经网络预测模型对极限抗拔承载力训练集的预测效果较好, 预测值和真实值几乎完全重合, 说明所建立的预测模型是可靠的, 可以用于预测复合基础的极限抗拔承载力。

5.4 预测结果及对比分析

1) 预测结果

将测试集中 6 种影响因素数据分别输入训练完成的 IPOA-BP、POA-BP 和 BP 神经网络预测模型, 3 种算法输出的复合基础承载力预测结果和真实值曲线如图 7 所示。

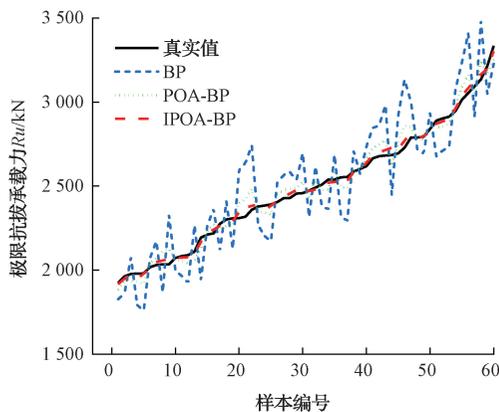


图 7 复合基础极限承载力预测曲线

Fig. 7 Composite foundation ultimate bearing capacity prediction curve

由图 7 可以看出, 相较于 POA-BP 和传统 BP 神经网络, 改进后的 IPOA-BP 神经网络算法预测值波动范围更小, 更接近真实值。

为了更直观地对比各预测效果, 将 BP、POA-BP 和 IPOA-BP 的预测值与真实值作差, 得到预测相对误差曲线如图 8 所示。

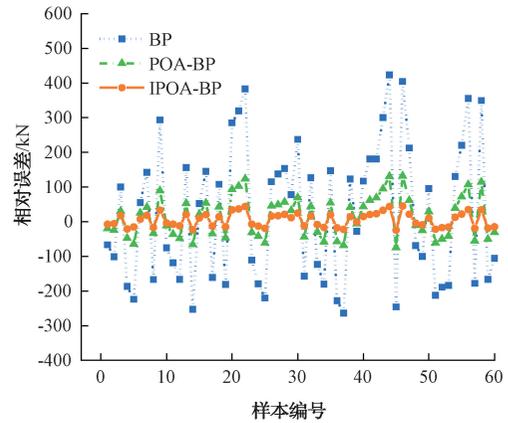


图 8 复合基础极限承载力相对误差曲线

Fig. 8 Relative error curve of ultimate bearing capacity of composite foundation

由图 8 可以看出, IPOA-BP 神经网络算法的结果始终位于真实值 ± 45.02 kN 内 (小于 $\pm 3\%$), 与真实值较接近, 较 POA-BP 和 BP 神经网络预测结果分别提升了 2.9 倍和 9.4 倍, 预测准确性大大提高。

2) 评价指标

本文选取均方根误差 (root mean square error, RMSE)、平均绝对百分误差 (mean absolute percentage error, MAPE) 和平均绝对误差 (mean absolute error, MAE) 3 个指标, 评价 IPOA-BP 神经网络预测模型的准确性。3 个评价指标值越小, 代表模型预测值越准确, 更接近真实值, 公式分别为:

$$RMSE = \sqrt{\frac{1}{h} \sum_{t=1}^h [\hat{y}(t) - y(t)]^2} \quad (17)$$

$$MAPE = \frac{1}{h} \sum_{t=1}^h \left| \frac{\hat{y}(t) - y(t)}{y(t)} \right| \quad (18)$$

$$MAE = \frac{1}{h} \sum_{t=1}^h |\hat{y}(t) - y(t)| \quad (19)$$

式中: h 为测试集中输出结果个数; $\hat{y}(t)$ 为复合基础极限抗拔承载力 R_u 真实值; $y(t)$ 为复合基础 R_u 预测值。

3) 对比分析

分别将 BP、POA-BP 和 IPOA-BP 预测模型的预测值和真实值, 代入式 (17)~(19), 计算 RMSE、MAPE 和 MAE, 结果如表 5 所示。

表 5 各算法预测误差对比

Table 5 Comparison of prediction errors of the algorithms

算法	RMSE	MAE	MAPE/%
BP	200.27	179.50	7.23
POA-BP	61.33	54.31	2.18
IPOA-BP	21.00	18.58	0.75

从表 5 可以看出, IPOA-BP 预测模型的 3 种评价指

标均优于其他模型,其中与 POA-BP 算法相比,IPOA-BP 模型的 RMSE 值下降 65.75%、MAE 值下降 65.79%、MAPE 值下降 65.60%,表明 IPOA-BP 算法预测输电塔复合基础极限抗拔承载力具有较好的精度。

6 结论

输电铁塔短桩-斜锚复合基础的极限抗拔承载力受多种因素影响,利用传统理论方法推导包含众多影响因素的承载计算公式,较为困难且精度较低。针对此问题,本文提出一种 IPOA-BP 神经网络预测模型,实现对输电塔复合基础极限抗拔承载力较准确的预测,主要得到如下结论。

1) 改进后的 IPOA 寻优性能提升明显,可以有效跳出局部最优。通过 SPM 混沌映射初始化鸚鵡种群,丰富了种群多样性;引入 Levy 飞行策略使鸚鵡得到一次额外的小范围搜索,增强了 POA 算法的全局搜索能力;融合非线性惯性权重因子 ω 的正余弦优化策略,有效平衡了算法全局和局部的勘探、开发能力。

2) 相较于 POA、WOA、GWO,IPOA 在收敛精度和收敛速度方面,具有更为出色的寻优性能;利用 IPOA 算法对 BP 神经网络的权值和阈值进行优化,能够有效改善 BP 神经网络选参时出现收敛速度慢、精度低的问题。

3) 在复合基础极限抗拔承载力预测方面,IPOA-BP 神经网络有着更好的预测精度和收敛速度;其中,IPOA-BP 神经网络与 POA-BP 神经网络相比,RMSE 值、MAE 值和 MAPE 值分别下降 65.75%、65.79%和 65.60%。

参考文献

- [1] 王彦海,任文强,刘晓亮,等.一种输电铁塔用装配式板式基础的设计与模拟[J].混凝土与水泥制品,2021(6):35-40,45.
WANG Y H, REN W Q, LIU X L, et al. Design and simulation of an assembled slab foundation for power transmission towers[J]. Concrete and Cement Products,2021(6):35-40,45.
- [2] 王彦海,任文强,刘晓亮,等.基于精细化建模方法的栓接装配式基础有限元分析[J].混凝土,2022(6):134-141.
WANG Y H, REN W Q, LIU X L, et al. Finite element analysis of bolted assembled foundation based on refined modeling method[J]. Concrete, 2022(6): 134-141.
- [3] 崔强,邢明,杨文智,等.喀斯特地区短桩锚杆复合基础现场抗拔试验及设计方法研究[J].岩石力学与工程学报,2018,37(11):2621-2630.
CUI Q,XING M,YANG W ZH, et al. Research on field pullout test and design method of short pile-anchor composite foundation in karst area[J]. Journal of Rock Mechanics and Engineering, 2018, 37(11): 2621-2630.
- [4] 中华人民共和国行业标准编写组.架空输电线路基础设计技术规程 DL/T 5219—2014 [S].北京:中国计划出版社,2018.
People's Republic of China Industry Standard Writing Group. Technical specification for foundation design of overhead transmission lines DL/T 5219—2014 [S]. Beijing: China Planning Press, 2018.
- [5] 中华人民共和国行业标准编写组.架空输电线路锚杆基础设计规程:DL/T 5522—2018[S].北京:中国计划出版社,2018.
People's Republic of China Industry Standard Writing Group. Design regulations for anchor foundation of overhead transmission lines: dl/t 5522—2018 [S]. Beijing: China Planning Press, 2018.
- [6] 孙义舟,孙宏磊,蔡袁强.桩-锚复合基础上拔承载力计算和参数影响研究[J].上海交通大学学报,2022,56(6):701-709.
SUN Y ZH,SUN H L,CAI Y Q. Calculation of uplift bearing capacity of pile-anchor composite foundation and study on the influence of parameters[J]. Journal of Shanghai Jiao Tong University, 2022, 56(6): 701-709.
- [7] 王彦海,尹恒伟,李建林,等.短桩斜锚复合基础抗拔承载特性分析与计算[J/OL].建筑科学与工程学报,1-12[2024-03-28].<http://kns.cnki.net/kcms/detail/61.1442.TU.20230526.1722.002.html>.
WANG Y H, YIN H W, LI J L, et al. Analysis and calculation of pullout bearing characteristics of short pile inclined anchor composite foundation [J/OL]. Journal of Building Science and Engineering, 1-12 [2024-03-28]. <http://kns.cnki.net/kcms/detail/61.1442.TU.20230526.1722.002.html>.
- [8] 刘仲洋,李冰阳,黄铁森,等.采用 BP-ANN 模型的梁柱平齐端板连接节点极限抗弯承载力预测研究[J].建筑结构,2023,53(5):119-126.
LIU ZH Y, LI B Y, HUANG Y M, et al. Prediction of ultimate flexural capacity of beam-column flush end plate connection nodes using BP-ANN model [J]. Building Structure, 2023, 53(5): 119-126.
- [9] 渠建伟.基于 BP 神经网络的振冲碎石桩复合地基承载力预测[J].铁道建筑,2017(4):87-90.
DRAINAGE J W. Prediction of bearing capacity of composite foundation with vibrated rubble pile based on BP neural network [J]. Railway Construction, 2017(4):87-90.
- [10] 蒋建平.基于 BP 神经网络的横向受荷桩承载力预测[J].水运工程,2017(1):158-163.

- JIANG J P. Prediction of bearing capacity of lateral ly loaded pile based on BP neural network[J]. Water Transportation Engineering,2017(1):158-163.
- [11] 王昆明,蒋洪胜,姜千君. 嵌岩桩竖向承载力预测的遗传BP神经网络模型研究[J]. 山东建筑大学学报, 2008,23(6):529-534.
- WANG K M,JIANG H SH,JIANG Q J. Genetic BP neural network modeling for prediction of vertical bearing capacity of embedded rock piles[J]. Journal of Shandong University of Architecture, 2008, 23(6):529-534.
- [12] SHU J K, YUAN G J, HUANG Z H, et al. The behaviour of the power transmission tower subjected to horizontal support's movements[J]. Engineering Structures, 2016, 123: 166-180.
- [13] PAVEL T, MOHAMMAD D. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications [J]. Sensors, 2022, 22(3): 855.
- [14] 班多哈,吕鑫,王鑫元. 基于一维混沌映射的高效图像加密算法[J]. 计算机科学,2020,47(4):278-284.
- BAN D H, LYU X, WANG X Y. An efficient image encryption algorithm based on one-dimensional chaotic mapping [J]. Computer Science, 2020, 47(4):278-284.
- [15] 高超,孙谊娟,赵洪峰,等. 基于 ICOA-LSTM 的短期负荷预测研究[J]. 电子测量技术, 2022, 45(13): 88-95.
- GAO CH,SUN Y Q,ZHAO H F, et al. Research on short-term load forecasting based on ICOA-LSTM[J]. Electronic Measurement Technology, 2022, 45(13): 88-95.
- [16] 周冬阳,王彦海,刘晓亮,等. 基于 IWOA-BP 神经网络的滑坡区塔线体系应力预测模型[J]. 国外电子测量技术,2023,42(7):121-131.
- ZHOU D Y, WANG Y H, LIU X L, et al. Stress prediction model of tower line system in landslide area based on IWOA-BP neural network [J]. Foreign Electronic Measurement Technology, 2023, 42(7): 121-131.
- [17] 黄学雨,罗华. 融合正余弦策略的算术优化算法[J]. 计算机工程与科学,2023,45(7):1320-1330.
- HUANG X Y, LUO H. An arithmetic optimization algorithm incorporating the sine-cosine strategy[J]. Computer Engineering and Science, 2023, 45(7): 1320-1330.
- [18] 程翠娜,奉松绿,莫礼平. 基于正余弦优化算子和 Levy 飞行机制的和声搜索算法[J]. 数据采集与处理, 2023,38(3):690-703.
- CHENG C N, FENG S L, MO L P. Harmony search algorithm based on positive cosine optimization operator and Levy flight mechanism[J]. Data Acquisition and Processing,2023,38(3):690-703.
- [19] 石磊. 一种改进的正弦余弦优化算法[D]. 武汉:武汉大学,2019.
- SHI L. An improved sine-cosine optimization algorithm [D]. Wuhan ;Wuhan University,2019.
- [20] GARCIA S, MOLINA D, LOZANO M, et al. A study on the use of non-parametric tests for analyzing the evolutionary algorithms behavior: A case study on the CEC 2005 special session on real parameter optimization [J]. Journal of Heuristics, 2009, 15(6): 617-644.
- [21] 刘智睿,杨志刚,赵志伟,等. 决策空间自组织多模态多目标鲸鱼优化算法研究[J]. 电子测量技术, 2023, 46(4):48-55.
- LIU ZH R, YANG ZH G, ZHAO ZH W, et al. Research on self-organized multimodal multi-objective whale optimization algorithm in decision space [J]. Electronic Measurement Technology, 2023, 46(4): 48-55.
- [22] 陈敏,陈晔,牛兴龙,等. 求解全局优化问题的多策略改进灰狼算法[J]. 国外电子测量技术,2022,41(11): 22-29.
- CHEN M, CHEN Y, NIU X L, et al. Multi-strategy improved gray wolf algorithm for solving global optimization problems [J]. Foreign Electronic Measurement Technology,2022,41(11):22-29.
- [23] 胡少伟,李原昊,单常喜,等. 基于改进的 PSO-BP 神经网络的边坡稳定性研究[J]. 防灾减灾工程学报, 2023,43(4):854-861.
- HU SH W, LI Y H, SHAN CH X, et al. Slope stability study based on improved PSO-BP neural network [J]. Journal of Disaster Prevention and Mitigation Engineering,2023,43(4):854-861.
- [24] 许泽海,赵燕东. 融合物联网多环境参数的茎干水分 SSA-BP 预测模型[J]. 农业工程学报,2023,39(16): 150-159.
- XU Z H, ZHAO Y D. Stem moisture SSA-BP prediction model incorporating multiple environmental parameters from internet of things[J]. Journal of Agricultural Engineering, 2023, 39(16):150-159.

作者简介

杨世强,硕士,工程师,主要研究方向为输电线路运检、高电压与绝缘技术。
E-mail:165516071@qq.com

李小来,本科,高级工程师,主要研究方向为输电线路运检及安全管理。

E-mail:yelxl1517@163.com

王彦海(通信作者),博士,副教授,主要研究方向为输电线路工程。

E-mail:45245356@qq.com

曹铖,硕士,工程师,主要研究方向为超特高压输电线

路运检。

E-mail:cc250597255@163.com

马立,工程师,技师,主要研究方向为超、特高压输电运检。

E-mail:3377876960@qq.com

尹恒伟,硕士研究生,主要研究方向为输电线路工程。

E-mail:2442889485@qq.com