

doi:10.12068/j.issn.1005-3026.2025.20240105

IWOA-Elman神经网络及其在充填体 强度预测中的应用

高浩然, 刘洪磊, 车德福, 兰天行
(东北大学 资源与土木工程学院, 辽宁 沈阳 110819)

摘要: 矿山充填体单轴抗压强度是保障采场稳定性的关键指标, 针对传统试验测定耗时低效的问题, 为实现高效精准预测, 提出一种融合混沌映射、自适应权重和Levy飞行的改进鲸鱼优化算法(IWOA). 采用IWOA优化Elman神经网络的权值与阈值, 构建IWOA-Elman预测模型. 基于某矿山充填体配比数据, 以水泥、粉煤灰和尾砂质量分数为输入, 抗压强度为输出, 训练并测试模型. 与Elman, PSO-Elman及WOA-Elman模型对比结果表明, IWOA收敛性能更优; IWOA-Elman模型的均方根误差(RMSE)和平均绝对百分比误差(MAPE)分别为0.0507和3.3269, 精度更高. 该模型对充填体强度预测及智能化充填设计具有一定的参考价值.

关键词: 智能化充填; 改进鲸鱼优化算法; Elman神经网络; IWOA-Elman预测模型; 充填体强度预测
中图分类号: TD 35 **文献标志码:** A **文章编号:** 1005-3026(2025)11-0125-09

IWOA-Elman Neural Network and Its Application to Backfill Strength Prediction

GAO Hao-ran, LIU Hong-lei, CHE De-fu, LAN Tian-xing

(School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: CHE De-fu, E-mail: chedefu@mail.neu.edu.cn)

Abstract: Uniaxial compressive strength of mine backfill is critical for slope stability. In response to the problem of low efficiency and long time consumption in traditional testing methods, an improved whale optimization algorithm (IWOA) incorporating chaotic mapping, adaptive weighting, and Levy flight was proposed. IWOA was used to optimize the weights and thresholds of an Elman neural network, and an IWOA-Elman prediction model was constructed. Based on backfill proportioning data from a mine, the model was trained and tested with mass fractions of cement, fly ash, and tailings as inputs and compressive strength as output. Comparative analysis with Elman, PSO-Elman, and WOA-Elman models demonstrates superior convergence of IWOA. The root mean square error (RMSE) and mean absolute percentage error (MAPE) of the IWOA-Elman model are 0.0507 and 3.3269, respectively, indicating higher accuracy. The model provides a valuable reference for backfill strength prediction and intelligent backfill design.

Key words: intelligent backfill; improved whale optimization algorithm; Elman neural network; IWOA-Elman prediction model; backfill strength prediction

作为众多支柱产业的基础, 矿业对我国发展至关重要. 然而随着开采条件恶化和环境污染加剧, 尾矿等废料管理问题日益突出^[1]. 充填采矿法

可有效提高资源利用率, 契合矿山绿色安全发展理念. 当前, 其正向智能化方向发展^[2], 如何将充填的特性与目标紧密结合, 充分利用云物移等技

收稿日期: 2024-05-07

基金项目: 国家自然科学基金资助项目(52174070).

作者简介: 高浩然(2000—), 男, 山西临汾人, 东北大学硕士研究生; 刘洪磊(1981—), 男, 山东枣庄人, 东北大学教授, 博士生导师; 车德福(1970—), 男, 山东海阳人, 东北大学教授, 博士生导师.

术手段实现智能化充填,是当前的主攻方向^[3].在具体实现中,基于数据驱动的建模与分析至关重要,其核心预测任务可分为分类识别(如采空区风险分级)和回归预测(如充填材料性能预测)两类.其中充填材料的强度预测是回归问题的一个重要分支,该研究对维持井下采场稳定、确保井下作业安全尤为重要.一般而言,科学的充填体强度预测方法需以试验数据为基础,在减少重复性试验成本的同时提供决策支持.同时密度、灰砂质量比、养护时间等都是影响充填体强度的因素,且呈高度复杂的非线性特征^[4].在现阶段研究中,充填体的抗压强度值主要依赖于物理试验,如全面试验法^[5]和正交试验法^[6].这些方法通过试验组合并利用模拟软件建立映射关系,为矿山工程设计提供了基础数据和关键方案.但仍面临试验周期较长、参数组合局限性问题.针对充填体这类多相复合的力学介质,探索高效辅助预测方法,依托已有试验数据减少对大规模物理试验的依赖,降本增效并为智能充填系统实时决策提供支持,具有重要现实意义.因此,国内外许多学者将AI方法引入到充填材料强度预测中.人工神经网络(artificial neural network, ANN)凭借其非线性动态处理能力显著提升了预测精度和速度.张钦礼等^[7]结合分级尾砂胶结充填方案,建立了反向传播(back-propagation, BP)神经网络预测模型.后来学者们将群智能优化算法与AI方法结合,开创了新方向.吴炜等^[8]通过将粒子群算法和ANN结合,优化其初始权值和阈值,实现了高精度预测.

总结来看, AI方法擅长处理非线性回归问题,群智能算法则用于优化模型的超参数.作为优化工具,其本身也在迭代更新,其中2016年提出的鲸鱼优化算法^[9]因具有易跳出局部最优、参数简单且精度高等特点,在电力调度、图像分割等领域应用广泛,但在矿山充填体强度预测中应用较少.本文构建IWOA-Elman充填体强度预测模型,通过改进鲸鱼算法优化Elman网络权值和阈值,基于组分数据预测抗压强度,验证了算法优越性和模型准确性,为矿山充填配比提供理论支持.

1 方法与原理

1.1 Elman神经网络

Elman神经网络是一种具有局部记忆单元和局部反馈连接的递归神经网络^[10].该网络在BP神经网络的基础上进行改进,在隐含层增加了一

个承接层作为延时算子,使其具备适应时变特性的能力,增强了网络的全局稳定性,同时提高了计算效率,适合用于解决快速求优问题. Elman网络由输入层、隐含层、承接层和输出层4部分组成^[11],其整体结构如图1所示.图中 y_0, y_1, \dots, y_n 表示输出层的预测结果; z_0, z_1, \dots, z_p 表示隐含层的神经元输出值; x_0, x_1, \dots, x_m 表示输入层的输入特征数据; c_0, c_1, \dots, c_q 表示承接层存储的隐含层历史状态值.

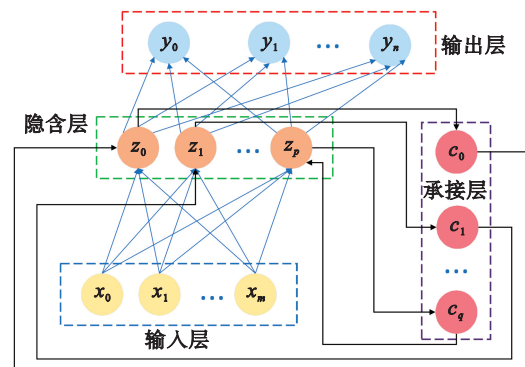


图1 Elman神经网络结构示意图

Fig. 1 Structure of Elman neural network

但是由于Elman神经网络参数过多及其非凸属性,会带来收敛速度过慢、易陷入局部最优等问题,通常需要借助优化算法调整网络结构来改善其训练效果和性能.

1.2 改进的鲸鱼优化算法

1.2.1 传统鲸鱼优化算法

鲸鱼优化算法(whale optimization algorithm, WOA)是一种模拟鲸鱼捕猎行为的元启发式算法,其核心是气泡网攻击机制(用螺旋移动模拟).该算法具有收敛快、全局搜索能力强、参数少等优点,主要包括围捕猎物、气泡网攻击和搜索捕食3个阶段^[12].

1) 围捕猎物.假设解空间的维度为 s ,当前最佳鲸鱼个体的位置表示为 X^* ,每一个体位置为 X^i ,则每一个体 X^i 在最佳个体 X^* 的影响下的下一个位置表示为 X^{i+1} ,具体计算公式如下:

$$X_k^{i+1} = X_k^* - A_1 \cdot D_k, \quad (1)$$

$$D_k = \|C_1 \cdot X_k^* - X_k^i\|, \quad (2)$$

$$C_1 = 2r_2, \quad (3)$$

$$A_1 = 2a \cdot r_1 - a. \quad (4)$$

其中: X_k^{i+1} 表示解空间中 X^{i+1} 的第 k 个分量, $k \in [1, s]$; D_k 表示当前最佳个体与当前个体之间的距离向量; A_1 和 C_1 为系数向量; a 为收敛因子,随着迭代次数的增加从2线性递减至0; r_1 和 r_2 均为 $[0, 1]$ 之间的随机数.

2) 气泡网攻击. 构建两种数学模型来模拟鲸鱼吐气泡捕食行为, 当前最佳鲸鱼位置为 X^* , 鲸鱼个体位置为 X^i , 模型描述如下: ①收缩包围机制: 当前个体的位置逐步向当前最佳位置的个体靠拢, 缩小 A_1 的取值范围为 $[-1, 1]$, 其余参数保持不变; ②螺旋更新位置: 当前个体沿螺旋轨迹向当前最优个体逼近, 描述如下:

$$X_k^{i+1} = X_k^* + D_k \cdot e^{cl} \cdot \cos(2\pi l), \quad (5)$$

$$D_k = |X_k^* - X_k^i| \quad (6)$$

其中: X_k^* 表示最优个体第 k 个位置坐标 (解空间第 k 个分量); X_k^i 表示第 i 个个体在第 k 个位置坐标; c 为常量系数, 决定鲸鱼螺旋前进的螺旋线形状; l 为 $[-1, 1]$ 内的随机数. 算法设定鲸鱼以 50% 的概率选择收缩包围圈或以螺旋式路线向猎物游走, 即

$$X_k^{i+1} = \begin{cases} X_k^* - A_1 \cdot D_k, & p < 0.5; \\ X_k^* + D_k \cdot e^{cl} \cdot \cos(2\pi l), & p \geq 0.5. \end{cases} \quad (7)$$

3) 搜索捕食. 限定 A_1 的范围为 $[-1, 1]$, 但当 A_1 不在该范围内时, 该个体转而随机靠近其他个体, 显著增强算法全局搜索能力. 假设随机选择

的个体位置为 X^{rand} , 其余符号定义同上, 则对应的模型为

$$X_k^{i+1} = X_k^{\text{rand}} - A_1 \cdot D_k, \quad (8)$$

$$D_k = \|C_1 \cdot X_k^{\text{rand}} - X_k^i\|. \quad (9)$$

1.2.2 改进策略

针对传统算法易陷于局部最优、收敛速度慢的缺陷, 为确保其工程应用的适应性、稳定性与精度, 本文从种群初始化、收敛系数修正及全局搜索优化 3 个方面提出改进策略以提升算法性能.

1) Cubic 混沌映射初始化种群. 混沌是一种对初始值敏感且具有随机特性的非线性动力系统^[13], 采用混沌映射替换固定种群初始化策略, 可在提升收敛速度的同时保持种群多样性, 从而增强算法寻优性能. 本文采用经典的 Cubic Map 混沌系统, 其映射公式如下:

$$x_{n+1} = \rho x_n (1 - x_n^2). \quad (10)$$

式中: $x_n \in (0, 1)$; ρ 为控制参数, 决定了映射的混沌特性, 当 ρ 取值 2.595 时, Cubic 混沌映射的直方图和分布图如图 2 所示, 具有较好的混沌遍历效果.




图2 Cubic混沌映射效果图

Fig. 2 Effect diagram of the Cubic chaotic mapping

(a)—Cubic映射直方图; (b)—Cubic映射分布图.

2) 自适应参数. ①收敛因子 a 的非线性改进. 系数向量 A_1 调节鲸鱼个体 3 种行为的互补制约关系, 维持局部与全局搜索的平衡. 其通过收敛因子 a 平衡全局和局部搜索, 针对传统算法中 a (从 2 到 0 线性递减) 导致后期易陷入局部最优的问题, 提出采用斜率变化曲线, 在迭代后期扩大搜索范围, 显著增强跳出局部最优的能力. 本文使用的曲线公式见式 (11), 示意图如图 3 所示.

$$a = a_0 \cdot e^{-\left(\tan\left(1.2 \times \frac{g}{T}\right)\right)^2}. \quad (11)$$

式中: g 表示当前迭代次数; T 表示最大迭代次数; a_0 表示收敛因子 a 的初始取值, 赋值为 2.




图3 收敛因子 a 的非线性改进曲线

Fig. 3 Nonlinear improved curve of convergence coefficient a

②启发式概率. 为模拟鲸鱼捕猎的收缩包围和螺旋上升行为, 传统算法基于随机概率 $p \in [0, 1]$ 判断行为模式. 本文为了平衡标准算法中的全局搜索和局部搜索能力, 采用启发式概率 p_h 对算法进行改进, 公式如下:

$$p_h = \begin{cases} 0.7, & p < 0.5T; \\ 0.4, & p \geq 0.5T. \end{cases} \quad (12)$$

③自适应惯性权重. 为充分利用最优解信息, 引入自适应惯性权重, 动态平衡全局搜索与局部开发能力, 提高算法寻优精度, 自适应惯性权重 w 的计算公式改进如下^[14]:

$$w(g) = \frac{2}{\pi} \arcsin\left(\frac{g}{T}\right). \quad (13)$$

具体应用时, 当 $p < p_h$ 时, 采用收缩包围机制, 再根据收敛向量 A_1 的取值判断是否随机搜索: 当 $|A_1| \geq 1$ 时, 采用 Levy 飞行策略进行全局位置更新; 当 $|A_1| < 1$ 时, 继续采用收缩包围机制. 当 $p \geq p_h$ 时, 则采用螺旋上升机制, 再次进行判断: 当 $|A_1| < 1$ 时, 在最优解周围螺旋; $|A_1| \geq 1$ 时, 维持全局搜索特性, 通过螺旋轨迹与随机搜索结合, 避免算法过早收敛.

$$X^{\text{new}}(g) = wX(g) + D e^{cl} \cos(2\pi l), |A_1| \geq 1, \quad (14)$$

$$X^{\text{new}}(g) = (1-w)X^*(g) + D e^{cl} \cos(2\pi l), |A_1| < 1. \quad (15)$$

式中: w 为改进的自适应惯性权重; D 为当前个体与最佳个体之间的距离向量; X^{new} 为更新后的位置向量.

3) 基于 Levy 飞行的全局搜索优化. Levy 飞行是一种将小范围搜索与大范围跳变相结合的随机行为策略, 用于模拟随机游走或搜索过程中的步长和方向变化, 具体更新公式如下:

$$X_{\text{new}}^l(g) = X^l(g) + A_1 \cdot 0.01 \cdot S \oplus (X^l(g) - C_1 \cdot X_{\text{rand}}(g)) \quad (16)$$

式中: $X^l(g)$ 和 $X_{\text{new}}^l(g)$ 分别表示使用 Levy 飞行策略前后鲸鱼个体的位置; l 为个体的编号; X_{rand} 表示随机一个鲸鱼个体的位置; \oplus 表示矢量乘积运算; S 为随机步长, 根据 Mantegna 方法产生:

$$S = \frac{\mu}{|\nu|^{\frac{1}{\beta}}}. \quad (17)$$

式中: β 为稳定性参数, 取值 1.5; μ 和 ν 均为 d 维空间向量, 分别服从 $N(0, \sigma_\mu^2)$ 和 $N(0, \sigma_\nu^2)$ 的正态分布, 对应的标准差分别为

$$\sigma_\mu = \left(\frac{\Gamma(1+\beta) \cdot \sin\left(\pi \cdot \frac{\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \cdot \beta \cdot 2^{\frac{\beta-1}{2}}}\right)^{\frac{1}{\beta}}, 1 < \beta \leq 2; \quad (18)$$

$$\sigma_\nu = 1. \quad (19)$$

式中, Γ 为伽马函数, $\Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$; $0 < \beta < 2$.

1.3 IWOA-Elman 优化模型

Elman 神经网络同样使用“梯度下降”算法进行参数更新和网络训练, 存在训练速度慢、易陷入局部最优解等缺点^[15]. 因此引入改进的鲸鱼优化算法, 将最终所得的全局最优解作为 Elman 神经网络的最优权值和阈值, 提升模型整体的预测精度和鲁棒性, IWOA-Elman 的实现步骤总结如下:

- 1) 获取数据并进行预处理;
- 2) 设置网络参数, 搭建基本 Elman 神经网络;
- 3) IWOA 参数初始化, 由 Elman 神经网络权重 w 和阈值 b 组成鲸鱼个体位置 $X(k)$:

$$X(k) = [w_1, w_2, w_3, b_1, b_2]. \quad (20)$$

- 4) 计算每一个体的适应度, 适应度函数 h 如下:

$$\min h(w_1, w_2, w_3, b_1, b_2) = \min \{\text{mean}(\text{MSE}_{\text{train}} + \text{MSE}_{\text{test}})\}. \quad (21)$$

式中: mean 表示求平均值; $\text{MSE}_{\text{train}}$ 和 MSE_{test} 分别表示训练集和测试集的均方误差, 计算方法为

$$\left. \begin{aligned} \text{MSE}_{\text{train}} &= \sum_{i=1}^M (Y_i^{\text{train}} - \hat{Y}_i^{\text{train}})^2 / M, \\ \text{MSE}_{\text{test}} &= \sum_{i=1}^N (Y_i^{\text{test}} - \hat{Y}_i^{\text{test}})^2 / N. \end{aligned} \right\} \quad (22)$$

式中: M 和 N 分别为训练集和测试集的样本数; Y_i 为真实结果; \hat{Y}_i 为网络预测结果.

- 5) 利用 IWOA 算法迭代更新, 找到最优适应度值的位置表示为

$$X(k)^{\text{best}} = [w_1^{\text{best}}, w_2^{\text{best}}, w_3^{\text{best}}, b_1^{\text{best}}, b_2^{\text{best}}]. \quad (23)$$

- 6) 对最优个体的位置进行解析, 将最优的权重和阈值提取并赋值给 Elman 神经网络, 执行网络训练操作, 直至达到误差阈值.

整体的技术路线如图 4 所示.

2 基于 IWOA-Elman 神经网络的充填体强度预测模型

2.1 数据来源及预处理

训练样本数据的质量决定了 Elman 神经网络

的性能、泛化能力和准确度^[16]. 本文选取张钦礼等^[7]的某矿山充填料浆配比试验数据集作为训练样本, 该数据集包含水泥质量分数、粉煤灰质量

分数和尾砂质量分数这 3 种影响充填体强度的配比因素, 以及对应的抗压强度输出结果.

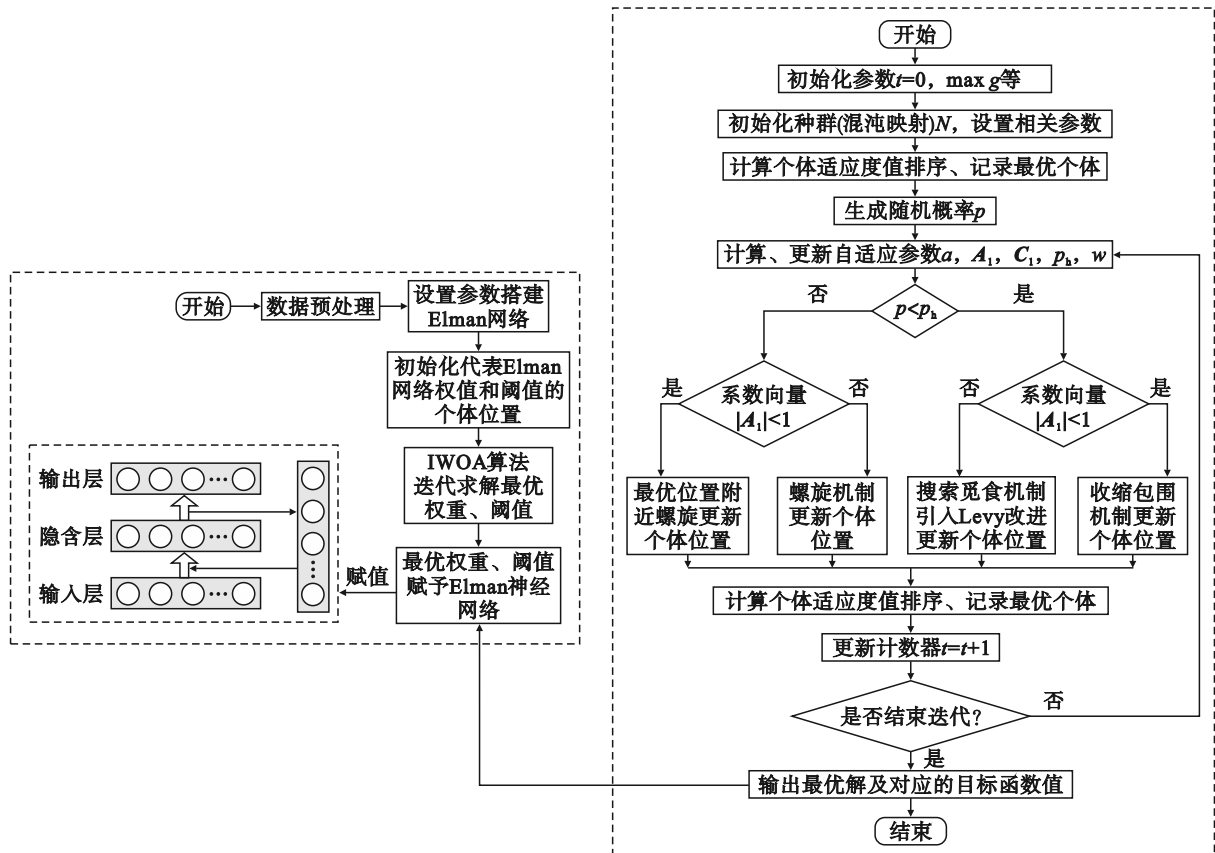


图 4 技术路线图

Fig. 4 Technology roadmap

为确保模型性能, 先对样本数据进行乱序处理以打破有序性、消除相关性; 采用留出法对预处理后的数据进行划分, 设定训练集占比 85%、测试集占比 15%, 并从训练集中另取部分作为验证集, 以避免过拟合或欠拟合现象^[17]; 此外, 由于样本参数数量级差异较大, 为消除维度影响并提升模型性能, 采用公式将数据归一化至 $[0, 1]$ 区间, 后续预测结果需通过反归一化处理得到真实值.

2.2 模型结构与参数设计

2.2.1 Elman 神经网络结构

基于输入变量(水泥质量分数、粉煤灰质量分数、尾砂质量分数)与输出变量(充填体抗压强度), Elman 神经网络结构确定为输入层 3 个神经元、输出层 1 个神经元.

隐含层神经元数量直接影响网络性能, 过多或过少会导致过拟合或欠拟合. 目前缺乏普适性的确定标准, 本文采用经验公式估算节点数量范围, 再使用试凑法确定最佳值^[18]:

$$N_{\text{hidden}} = \sqrt{N_{\text{in}} + N_{\text{out}}} + \alpha. \quad (24)$$

式中: N_{hidden} 为隐含层神经元个数; N_{in} 为输入层神经元个数, 取值为 3; N_{out} 为输出层神经元个数, 取值为 1; α 为 1~10 之间的常数. 通过重复试验, 结果如图 5 所示. 综合误差分析及网络性能考虑, 取隐含层节点个数为 5, 承接层的神经元个数应与隐含层保持一致. 综上, 最终确定 Elman 神经网络的输入层、隐含层、承接层和输出层的神经元个数分别为 3, 5, 5, 1.




图 5 隐含层最佳节点个数试验结果

Fig. 5 Results of optimal number of nodes in hidden layer

2.2.2 IWOA 参数设计

在改进鲸鱼优化算法(IWOA)中,设置种群规模为 30,最大迭代次数为 50,其优化维度(解空间维数)为 51.该维度由 Elman 神经网络结构决定,其中输入层 3 个节点、隐含层 5 个节点、承接层 5 个节点、输出层 1 个节点,对应了输入层到隐含层权重(3×5=15)、隐含层到承接层权重(5×5=25)、隐含层到输出层权重(5×1=5)、隐含层阈值(5×1=5)和输出层阈值(1×1=1)的总参数数量.算法输出的最优解是一个 1×51 维向量,需按此顺序提取元素并重构为对应的 5 个权重和阈值矩阵.

2.3 模型评价指标

为了验证 IWOA-Elman 模型的拟合效果和优势,本文拟建立多种不同的回归预测模型进行对比分析.为比较各模型的优劣,分析预测模型的有效性和准确性,采用如下几种评价指标:

平均绝对误差 δ_{MAE} 为

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (25)$$

均方根误差 δ_{RMSE} 为

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (26)$$

拟合优度 R^2 为

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

平均绝对百分比误差 δ_{MAPE} 为

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%. \quad (28)$$

式中: n 代表用于训练或测试的样本数量; y_i 为数据的真实值; \hat{y}_i 为数据的预测值; \bar{y} 为数据的平均值. δ_{MAE} , δ_{RMSE} , δ_{MAPE} 均可以较好地反映预测值和真实值的误差情况,结果越小,则表示模型对于充填体强度的预测性能越好. R^2 越大(接近 1),表示模型拟合效果越好,预测精度越高.

3 算法仿真与实例预测分析

3.1 算法的性能测试

通过试验最终选定 8 个基准测试函数,从收敛速度、收敛精度和全局搜索能力等方面对改进算法的寻优性能进行测试.为更直观地展示改进算法的优势,引入遗传算法(GA)、粒子群优化(PSO)算法、灰狼优化(GWO)算法以及标准鲸鱼优化算法(WOA)进行对比测试.为保证结果的可靠性,每种算法均独立重复运行 30 次,种群数量为 30,函数维度为 30,最大迭代次数为 500.

本文算例中采用算法多次独立运行所得目标函数值的平均值、标准差、运行时间和最优值作为标准对算法结果进行评价,试验结果如表 1 所示.同时展示了 IWOA 和其他 4 种算法的收敛曲线对比如图 6 所示,使对比更为直观.

表 1 5 种算法的寻优性能比较

Table 1 Comparison of optimization performance of five algorithms

测试函数	评价标准	GA	PSO	GWO	WOA	IWOA
F1	平均值	96 196.995 2	26.193 0	1.44E-17	1.44E-71	4.53E-233
	标准差	15 688.467 3	7.782 6	1.26E-17	7.24E-71	0
	运行时间/s	0.046 7	0.094 9	0.088 5	0.032 4	0.035 9
	最优解	63 125.415 2	14.353 6	1.37E-18	7.35E-90	0
F2	平均值	40.763 2	4.841 5	8.74E-17	5.61E-51	4.09E-123
	标准差	6.721 5	1.821 6	4.864E-17	1.59E-50	2.09E-122
	运行时间/s	0.045 9	0.084 1	0.052 1	0.026 4	0.028 5
	最优解	27.947 0	2.367 2	2.20E-17	1.37E-58	0
F3	平均值	37 988.551 5	689.380 3	1.72E-05	40 759.439 9	3.99E-173
	标准差	9 551.639 6	1 559.514 7	3.51E-05	13 734.184 9	0
	运行时间/s	0.128 4	0.170 7	0.134 5	0.106 0	0.109 8
	最优解	22 527.125 2	43.465 7	1.35E-08	12 273.764 9	0
F4	平均值	69.545 0	3.742 7	1.04E-06	48.771 9	2.38E-100
	标准差	7.971 9	0.961 3	1.18E-06	28.136 3	1.30E-99
	运行时间/s	0.045 0	0.085 9	0.048 8	0.024 7	0.027 9
	最优解	42.183 1	1.881 9	4.90E-08	0.430 6	0
F5	平均值	10 136.241 4	0.627 5	0.684 0	0.430 2	0.130 6
	标准差	5 161.029 3	0.157 9	0.339 9	0.240 5	0.039 9
	运行时间/s	0.044 8	0.085 2	0.048 9	0.024 5	0.026 9
	最优解	1 385.651 2	0.329 5	0.158 4	0.099 5	0.051 2

续表 1

测试函数	评价标准	GA	PSO	GWO	WOA	IWOA
F6	平均值	0.602 9	0.235 8	0.001 8	0.002 7	7.38E-05
	标准差	0.571 7	0.075 9	0.001 0	0.002 6	6.98E-05
	运行时间/s	0.094 2	0.132 6	0.100 0	0.075 3	0.077 5
	最优解	0.081 0	0.131 6	0.000 4	3.52E-05	2.34E-07
F7	平均值	7.572 9	2.559 2	0.043 0	0.025 3	0.009 2
	标准差	3.402 8	1.169 2	0.017 4	0.018 2	0.003 0
	运行时间/s	0.179 1	0.219 3	0.184 5	0.156 9	0.159 3
	最优解	2.429 9	0.353 6	0.013 2	0.005 1	0.004 8
F8	平均值	20.095 8	5.248 3	1.1E-13	4.56E-15	8.88E-16
	标准差	0.389 0	0.812 3	1.8E-14	1.98E-15	0
	运行时间/s	0.057 4	0.095 4	0.053 1	0.029 3	0.031 2
	最优解	19.094 6	3.443 4	7.55E-14	8.88E-16	8.88E-16

分析结果表明,针对 8 个基准测试函数,本文提出的 IWOA 算法的寻优精度显著优于传统的 GA 和 PSO 算法;对于较新的 GWO 和传统 WOA 算法,其优势也非常明显,均接近于理论值. IWOA 算法在处理测试函数 F1~F4 均取得了理论

最优解, F1, F3 和 F8 的标准差也达到了 0. 此外,运行时间对比表明, IWOA 算法运行效率与 WOA 基本持平,且显著优于其余 3 种算法,在提升寻优性能的同时未增加时间开销.




图 6 测试函数运行对比

Fig. 6 Comparison of test function operation

- (a) — 函数 F1 收敛曲线; (b) — 函数 F2 收敛曲线; (c) — 函数 F3 收敛曲线; (d) — 函数 F4 收敛曲线;
- (e) — 函数 F5 收敛曲线; (f) — 函数 F6 收敛曲线; (g) — 函数 F7 收敛曲线; (h) — 函数 F8 收敛曲线.

通过分析图 6 可见,传统算法在大多数测试函数中都出现了早熟现象(即陷入局部最优解),收敛曲线基本都呈现平稳直线状,寻优效果不佳;而红色曲线代表的改进算法在收敛精度、收敛速度和稳定性方面均表现优异.通过融合多种策略,改进算法在收敛过程中多次出现拐点,有效改善了早熟现象,验证了改进算法的有效性和稳定性.

3.2 充填体强度预测结果分析

分别对 Elman, PSO-Elman, WOA-Elman 和 IWOA-Elman 共 4 种预测模型进行试验,每一种模型都独立运行 10 次,最终预测结果取平均值.对试验的分析和总结如下:首先,4 个模型训练集和测试集的 4 项评价指标见表 2. 单一的 Elman 模

型无论在训练集还是测试集上,其 δ_{MAE} , δ_{RMSE} 和 δ_{MAPE} 都是最大的,而且 R^2 最小,说明该模型预测性能最差,拟合效果不佳.引入 PSO 和 WOA 算法后,模型的性能有明显提升,各项误差指标显著减小,同时拟合优度也相应增大.本文提出的 IWOA-Elman 模型,在训练集上各指标均优于 PSO-Elman 模型,与 WOA-Elman 模型的差异仅为 0.001 数量级;而在测试集上得到了极大提升, δ_{MAE} 为 0.046 6, δ_{RMSE} 为 0.050 7, δ_{MAPE} 为 3.326 9%,均显著低于其他 3 个模型,且 R^2 达到 0.993 9,表明该模型具有更高的预测精度、最小的误差和最佳的预测效果.4 种模型的训练集拟合情况和测试集预测情况如图 7 所示.本文改进算法在保证训练高拟合度的同时,在预测阶段也表现出优越的性能.

表2 算法试验对比结果的预测模型评价指标

Table 2 Comparative results of algorithm tests and evaluation indicators of prediction models

预测模型	δ_{MAE}		δ_{RMSE}		R^2		$\delta_{MAPE}/\%$	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
Elman	0.126 4	0.163 0	0.186 5	0.182 2	0.965 1	0.921 5	12.640 0	16.300 0
PSO-Elman	0.114 6	0.155 8	0.135 0	0.175 4	0.981 8	0.927 3	9.997 7	13.866 6
WOA-Elman	0.092 4	0.139 9	0.133 0	0.154 3	0.982 3	0.943 7	7.164 2	10.403 6
IWOA-Elman	0.093 3	0.046 6	0.130 4	0.050 7	0.983 0	0.993 9	6.774 9	3.326 9

其次,具体的预测结果如表3所示,共4个预测样本.表中展示了其抗压强度实测值以及4个模型对应的预测值,同时计算了相对误差.可以看出IWOA-Elman模型的预测结果与实际值最为接近,每一个样本的相对误差均为最小.此外,4个模型对应的误差曲线如图8所示:本文模型

的误差在0附近很小范围内波动,其余3个模型误差较大且稳定性较差.根据预测准确率的计算方法($1-\delta_{MAPE}$),4类模型的预测准确率分别为83.702 5%,86.135 0%,89.597 5%,96.597 5%,证明本文所用算法对Elman神经网络的改进效果显著,可以很好地对充填体强度进行预测.

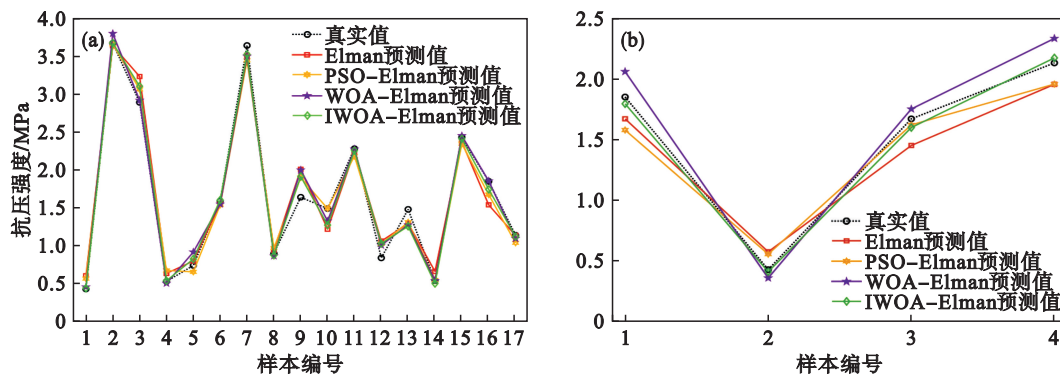


图7 模型训练集和测试集性能对比

Fig. 7 Comparison of model training set and test set performance

(a)—训练集拟合效果; (b)—测试集预测效果.

表3 模型预测误差及准确率

Table 3 Model prediction error and accuracy

样本序号	抗压强度实际值/MPa	Elman		PSO-Elman		WOA-Elman		IWOA-Elman	
		抗压强度预测值/MPa	相对误差/%	抗压强度预测值/MPa	相对误差/%	抗压强度预测值/MPa	相对误差/%	抗压强度预测值/MPa	相对误差/%
1	1.85	1.670 3	9.71	1.578 0	14.70	2.058 4	11.26	1.794 0	3.03
2	0.43	0.576 6	34.09	0.557 3	29.60	0.361 0	16.05	0.412 5	4.07
3	1.67	1.450 9	13.12	1.620 2	2.98	1.750 8	4.84	1.598 4	4.29
4	2.13	1.953 9	8.27	1.955 7	8.18	2.331 4	9.46	2.177 2	2.22
预测准确率/%		83.702 5		86.135 0		89.597 5		96.597 5	

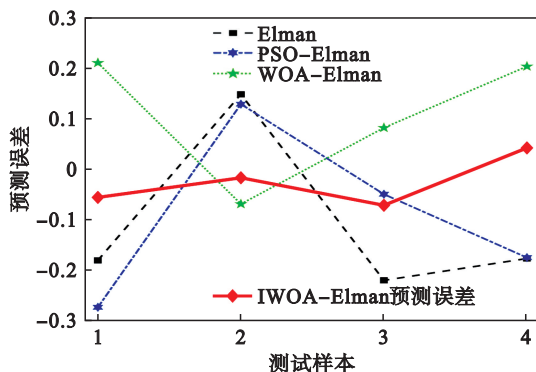


图8 预测模型误差对比曲线

Fig. 8 Error comparison curves of prediction models

4 结 论

1) 针对Elman神经网络易陷于局部最优及超参数随机初始化问题,提出采用改进鲸鱼优化算法(IWOA)优化其权值与阈值.基准测试表明,IWOA具备更高的收敛精度、更快的收敛速度以及更优的全局探索与局部开发能力.

2) 基于矿山充填料浆配比试验,提出了IWOA-Elman改进预测模型.实例验证和对比分析表明,该预测模型在保证收敛速度的同时可有

效降低充填体强度预测误差, 测试集的拟合优度为 0.993 9, 准确率为 96.597 5%。相较于其他模型, IWOA 可以更好地优化 Elman 的超参数, 模型预测性能更优, 具有较高的预测精度和鲁棒性。

3) 目前本预测模型还需要进行进一步的应用和比较, 需要收集更多的工程现场数据进行对比分析, 对预测模型的算法持续优化和改进。同时可扩充输出目标如泌水率、塌落度等, 构建多输入多输出的充填体性能集成预测模型, 为工程应用提供更全面支撑。

参考文献:

- [1] 刘具, 秦坤. 我国煤炭绿色开采技术进展[J]. 矿业安全与环保, 2023, 50(6): 7-15.
(Liu Ju, Qin Kun. Progress of green coal mining technology in China [J]. *Mining Safety & Environmental Protection*, 2023, 50(6): 7-15.)
- [2] Williams E. Environmental effects of information and communications technologies [J]. *Nature*, 2011, 479(7373): 354-358.
- [3] 齐冲冲, 杨星雨, 李桂巨, 等. 新一代人工智能在矿山充填中的应用综述与展望[J]. 煤炭学报, 2021, 46(2): 688-700.
(Qi Chong-chong, Yang Xing-yu, Li Gui-chen, et al. Research status and perspectives of the application of artificial intelligence in mine backfilling [J]. *Journal of China Coal Society*, 2021, 46(2): 688-700.)
- [4] 付自国, 乔登攀, 郭忠林, 等. 基于 RSM-BBD 的废石-风砂胶结体配合比与强度试验研究[J]. 煤炭学报, 2018, 43(3): 694-703.
(Fu Zi-guo, Qiao Deng-pan, Guo Zhong-lin, et al. Experimental research on mixture proportion and strength of cemented hydraulic fill with waste rock and colian sand based on RSM-BBD [J]. *Journal of China Coal Society*, 2018, 43(3): 694-703.)
- [5] 吴鹏, 王贻明, 吴爱祥, 等. 基于全面试验的钒铁矿开采充填材料配比优化研究[J]. 金属矿山, 2016(10): 5-10.
(Wu Peng, Wang Yi-ming, Wu Ai-xiang, et al. Optimization of mining filling material proportioning for a vanadium iron ore based on the thorough tests [J]. *Metal Mine*, 2016, (10): 5-10.)
- [6] 王新民, 徐东升. 胶结充填料优化配比研究及强度预测[J]. 矿业快报, 2006, 22(12): 20-23.
(Wang Xin-min, Xu Dong-sheng. Research on optimization proportioning of cemented filling material and strength forecasting [J]. *Express Information of Mining Industry*, 2006, 22(12): 20-23.)
- [7] 张钦礼, 李谢平, 杨伟. 基于 BP 网络的某矿山充填料浆配比优化[J]. 中南大学学报(自然科学版), 2013, 44(7): 2867-2874.
(Zhang Qin-li, Li Xie-ping, Yang Wei. Optimization of filling slurry ratio in a mine based on back-propagation neural network [J]. *Journal of Central South University (Science and Technology)*, 2013, 44(7): 2867-2874.)
- [8] 吴炜, 吉坤, 张朋, 等. 基于 ANN-PSO 模型的充填体强度预测及其工程应用[J]. 矿业研究与开发, 2020, 40(2): 53-57.
(Wu Wei, Ji Kun, Zhang Peng, et al. Strength prediction of filling body based on ANN-PSO model and its engineering application [J]. *Mining Research and Development*, 2020, 40(2): 53-57.)
- [9] Mirjalili S, Lewis A. The whale optimization algorithm [J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [10] Li X Y, Zhang L, Wang Z P, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks [J]. *Journal of Energy Storage*, 2019, 21: 510-518.
- [11] Hao J, Zhu C S, Guo X T. A new CIGWO-Elman hybrid model for power load forecasting [J]. *Journal of Electrical Engineering & Technology*, 2022, 17(2): 1319-1333.
- [12] Aljarah I, Faris H, Mirjalili S. Optimizing connection weights in neural networks using the whale optimization algorithm [J]. *Soft Computing*, 2018, 22(1): 1-15.
- [13] 元祥波, 陈阳, 郑铭. 面向柔性作业车间调度的多策略鲸鱼优化算法 [J]. 计算机系统应用, 2023, 32(9): 154-161.
(Qi Xiang-bo, Chen Yang, Zheng Ming. Multi-strategy whale optimization algorithm for flexible job shop scheduling [J]. *Computer Systems and Applications*, 2023, 32(9): 154-161.)
- [14] 郝晓弘, 宋吉祥, 周强, 等. 混合策略改进的鲸鱼优化算法 [J]. 计算机应用研究, 2020, 37(12): 3622-3626, 3655.
(Hao Xiao-hong, Song Ji-xiang, Zhou Qiang, et al. Improved whale optimization algorithm based on hybrid strategy [J]. *Application Research of Computers*, 2020, 37(12): 3622-3626, 3655.)
- [15] Zhang Y F, Zhao J P, Wang L M, et al. An improved OIF Elman neural network based on CSO algorithm and its applications [J]. *Computer Communications*, 2021, 171: 148-156.
- [16] Gupta T, Kumar R. A novel feed-through Elman neural network for predicting the compressive and flexural strengths of eco-friendly jarosite mixed concrete: design, simulation and a comparative study [J]. *Soft Computing*, 2024, 28(1): 399-414.
- [17] Xiong S, Liu Z X, Min C D, et al. Compressive strength prediction of cemented backfill containing phosphate tailings using extreme gradient boosting optimized by whale optimization algorithm [J]. *Materials*, 2023, 16(1): 308.
- [18] Wan S C, Yang H J, Lin J W, et al. Improved whale optimization algorithm towards precise state-of-charge estimation of lithium-ion batteries via optimizing LSTM [J]. *Energy*, 2024, 310: 133185.