

基于鲸鱼优化算法-反向传播神经网络的 钢筋混凝土耐久性预测

冯 琼^{1,2}, 谢晓扬¹, 王鹏辉³, 乔宏霞^{1,2}, 马云霞¹

(1. 兰州理工大学 土木工程学院, 兰州 730050; 2. 兰州理工大学 西部土木工程防灾减灾教育部工程研究中心, 兰州 730050; 3. 深圳大学 广东省滨海土木工程耐久性重点实验室, 广东 深圳 518060)

摘 要: 本文研究通过配合比设计提高钢筋混凝土的耐久性, 设计拓扑结构为6-14-2的鲸鱼优化算法-反向传播神经网络模型。模型数据集共100*2组数据, 其中60*2组数据用于建立模型, 40*2组数据用于验证模型。通过对比反向传播神经网络模型与鲸鱼优化算法-反向传播神经网络模型的预测性能, 表明鲸鱼优化算法可以显著提高反向传播神经网络模型的预测性能。鲸鱼优化算法-反向传播神经网络模型预测 T_1 性能指标的均值分别为 $R^2=0.90$ 、 $RMSE=33.92$ 、 $MAPE=0.06$ 、 $MAE=27.31$; T_2 性能指标的均值分别为 $R^2=0.90$ 、 $RMSE=29.75$ 、 $MAPE=0.04$ 、 $MAE=23.81$ 。可知, 鲸鱼优化算法-反向传播神经网络模型可以有效预测钢筋混凝土的耐久性。

关键词: 土木工程材料; 钢筋混凝土耐久性; 腐蚀电流密度; 混凝土损伤度; 鲸鱼优化算法-反向传播神经网络

中图分类号: TU528 文献标志码: A 文章编号: 1671-5497(2025)07-2276-10

DOI: 10.13229/j.cnki.jdxbgxb.20231096

Prediction of reinforced concrete durability based on whale optimization algorithm-back propagation neural network

FENG Qiong^{1,2}, XIE Xiao-yang¹, WANG Peng-hui³, QIAO Hong-xia^{1,2}, MA Yun-xia¹

(1. School of Civil Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 2. Western Ministry of Civil Engineering Disaster Prevention and Mitigation Engineering Research Center, Lanzhou University of Technology, Lanzhou 730050, China; 3. Guangdong Provincial Key Laboratory of Durability of Binhai Civil Engineering, Shenzhen University, Shenzhen 518060, China)

Abstract: To enhance the durability of reinforced concrete through mix design, a whale optimization algorithm-back propagation neural network model with a topology structure of 6-14-2 is designed. The model dataset comprises 100 2 sets of data, with 60×2 sets used for model establishment and 40×2 sets for model validation. By comparing the predictive performance of the backpropagation neural network model with the whale optimization algorithm-back propagation neural network model, it is evident that the whale optimization algorithm significantly improves the predictive ability of the back propagation neural network

收稿日期: 2023-09-23.

基金项目: 国家自然科学基金项目(52008196, U21A20150, 52178216); 甘肃省科技计划项目(23JRRA799).

作者简介: 冯琼(1985-), 女, 副教授, 博士. 研究方向: 钢筋混凝土耐久性. E-mail: fengqiong.1985@163.com

model. The whale optimization algorithm-back propagation neural network model predicts the mean values of T_1 performance indicators as follows: $R^2=0.90$, $RMSE=33.92$, $MAPE=0.06$, $MAE=27.31$; the mean value of T_2 performance indicators as follows: $R^2=0.90$, $RMSE=29.75$, $MAPE=0.04$, $MAE=23.81$. Therefore, the whale optimization algorithm-back propagation neural network model can effectively predict the durability of reinforced concrete.

Key words: civil engineering materials; durability of reinforced concrete; corrosion current density; concrete damage degree; whale optimization algorithm-back propagation neural network

0 引 言

西部盐渍土地区钢筋混凝土耐久性一直是研究的重点,由于盐渍土中存在大量的 SO_4^{2-} 、 Cl^- 等腐蚀性离子,导致钢筋混凝土耐久性显著下降。为应对此问题,研究人员通常采用低水胶比^[1-3]、掺加粉煤灰^[4,5]、掺加矿粉^[6]等配合比优化方法减轻腐蚀性离子对钢筋混凝土结构的影响,进而提高其耐久性。但是这些方法未能建立钢筋混凝土耐久性与配合比之间的函数关系,后续研究中仍需花费大量时间进行重复性实验。因此,亟需一种描述钢筋混凝土耐久性与配合比之间内在关联机制的函数方程,预测钢筋混凝土耐久性。

常用的钢筋混凝土耐久性预测模型^[7-9]未能与混凝土配合比设计环节之间建立紧密联系,主要是由于耐久性与配合比之间表现出复杂的非线性关系,难以用准确的数学公式来表达。鲸鱼优化算法-反向传播神经网络(Whale optimization algorithm-back propagation neural network, WOA-BPNN)^[10,11]具有自适应性、高度可调性与全局搜索能力,能够解决复杂的非线性映射问题,已经在预测混凝土抗压强度^[10]、混凝土板下空隙^[11]方面得到应用,使其应用于预测钢筋混凝土耐久性方面成为可能。

为研究不同配合比下钢筋混凝土的耐久性,本文设计了10组配合比,通过盐渍土环境通电实验对钢筋混凝土进行加速腐蚀劣化,以水泥、河砂、矿粉、粉煤灰、粗集料的用量与水胶比为输入参数,以钢筋混凝土中钢筋腐蚀电流密度达到高速腐蚀的时间 T_1 和混凝土保护层损伤度 >1 的时间 T_2 为输出参数,设计了拓扑结构为6-14-2的WOA-BPNN模型,旨在建立西部盐渍土地区钢筋混凝土耐久性预测模型,为研究钢筋混凝土耐久性与配合比设计之间的关系提供科学指导。

1 材料与方法

1.1 原材料

本研究采用直径为10 mm的HRB335热轧带肋钢筋,P·O 42.5普通硅酸盐水泥,细度模数为2.9的河砂,粗集料为5~25 mm连续级配碎石;Ⅱ级粉煤灰,95级矿粉,自来水,高效粉状减水剂。混凝土配合比如表1所示。

表 1 混凝土配合比
Table 1 Mix ratio of concrete kg/m³

组别	水泥	河砂	粗集料	粉煤灰	矿粉	水胶比	强度等级
A	390	685	1 165	0	0	0.40	C40
B	450	634	1 167	0	0	0.35	C50
C	480	630	1 137	0	0	0.32	C55
F-20	360	634	1 167	90	0	0.35	C50
F-30	315	634	1 167	135	0	0.35	C50
F-40	270	634	1 167	180	0	0.35	C50
S-20	360	634	1 167	0	90	0.35	C50
S-30	315	634	1 167	0	135	0.35	C50
S-40	270	634	1 167	0	180	0.35	C50
FS-15	315	634	1 167	67.5	67.5	0.35	C50

1.2 实验方案

钢筋先使用砂纸打磨,然后用丙酮除油,确保钢筋表面无锈斑、油污等杂质。

按照表1拌制混凝土,测得拌合物黏聚性和保水性均良好;然后根据GB/T 50081—2019《混凝土物理力学性能试验方法标准》成型尺寸为100 mm×100 mm×100 mm的立方体试件;为保证钢筋混凝土四周保护层厚度相同,将 ϕ 为10 mm、长度为100 mm的钢筋垂直置于试件正中位置,制备如图1所示的钢筋混凝土试件。本实验根据表1中的10组混凝土配合比制备试件,且每组均制备10个钢筋混凝土平行试件。

试件成型24 h后拆模,对外露钢筋缠绕铜线便于通电,然后涂抹环氧树脂防止外露钢筋在养护过程中锈蚀。标准养护28 d后进行盐渍土环境通电实验。

如图2所示,将试件竖直放入盐渍土中,电流




图1 钢筋混凝土试件示意图

Fig. 1 Schematic diagram of reinforced concrete specimen
密度设置为 $130\text{ }\mu\text{A}/\text{cm}^2$, 钢筋连接阳极, 石墨棒连接阴极。按照 GB/T 50123—2019 测试取自青海格尔木地区的盐渍土, 测试结果见表 2。根据测得样品中易溶盐成分及含量, 配制浓度为 134 g/L NaCl 与 $23\text{ g/L Na}_2\text{SO}_4$ 的复合盐溶液。为保证盐渍土内腐蚀离子浓度, 每周喷洒一次复合盐溶液。通电过程中定期在盐渍土中洒水, 保持木箱内盐渍土湿度在 80% 左右。




图2 试件加速腐蚀示意图

Fig. 2 Schematic diagram of accelerated corrosion of specimen

根据法拉第定律, 钢筋理论质量损失率 (Mass loss rate, MLR) 与通电时间满足式(1), 本研究设置 MLR 每增加 0.5% 进行一次指标测试, 即每个循环通电时间为 74 h。

$$t = \frac{\Delta m \times Z \times F}{M_{\text{Fe}} \times I} \tag{1}$$

式中: t 为通电时间(s); Δm 为钢筋理论质量损失量, g; Z 为反应电极化学价, $Z = \pm 2$; F 为法拉第常数, $F = 96\,500\text{ C/mol}$; M_{Fe} 为铁的摩尔质量, $M_{\text{Fe}} = 56\text{ g/mol}$; I 为电流强度, $I = 20 \times 10^{-3}\text{ A}$ 。

表2 盐渍土中易溶盐成分

Table 2 Soluble salt composition in saline soil

项目	阴离子含量/(mg·kg ⁻¹)				阳离子含量/(mg·kg ⁻¹)			总量/%
	CO ₃ ²⁻	HCO ₃ ⁻	SO ₄ ²⁻	Cl ⁻	Ca ²⁺	Mg ²⁺	Na ⁺ +K ⁺	/
盐渍土土样	59	181	15 648	81 016	5 840	397	22 887	12.603

1.3 劣化指标测试

每个循环结束后, 采用德国 ZahnerE 电化学工作站与北京海创 HC-C83 超声波测试仪分别进行电化学测试与声速测试。

电化学测试选用三电极体系, 工作电极为试件中的钢筋, 饱和甘汞电极为参比电极, 辅助电极为箔片。极化曲线频率为 0.33 Hz, 扫描速率为 0.334 mV/s, 腐蚀电位扫描范围为 -200~200 mV。根据 GB/T 50344—2019 关于腐蚀电流密度与钢筋腐蚀速率状态关系(见表 3), 计算钢筋的腐蚀电流密度 i_{corr} , 记录钢筋达到高速腐蚀的时间 T_1 。

表3 腐蚀电流密度与钢筋腐蚀速率对应关系

Table 3 Correspondence between corrosion current density and corrosion rate of steel bars

$i_{\text{corr}}/(\mu\text{A} \cdot \text{cm}^{-2})$	$i_{\text{corr}} < 0.2$	$0.2 \leq i_{\text{corr}} < 0.5$	$0.5 \leq i_{\text{corr}} < 1.0$	$1.0 \leq i_{\text{corr}} < 10$	$10 \leq i_{\text{corr}}$
腐蚀速率状态	钝化状态	低	中等	高	极高

根据 GB/T 50082—2024 规定进行声速测试, 式(2)为相对动弹性模量 E_r 与混凝土超声波波速 v 之间的关系, 设定当 E_r 降低到 60% 时判定为失效^[12]。定义经 t 时间后以混凝土的损伤度 D_t 来评价混凝土保护层损伤状态, 当 $D_t \geq 1$ 时, 钢筋混凝土试件失效, 记录失效时间 T_2 。

$$E_r = \frac{E_t}{E_0} = \frac{v_t^2}{v_0^2} \tag{2}$$

式中: E_0 为初始动弹性模量; E_t 为 t 时刻动弹性模量; v_t 为 t 时刻超声波声速; v_0 为初始超声波声速。

$$D_t = \frac{1 - E_r}{0.4} \tag{3}$$

式中: D_t 正常取值范围为 $[0, 1]$ 。

1.4 模型参数设置

本研究建立模型的数据集由 100*2 组数据 (共计 200 个数据) 组成。其中, 60*2 组数据 (共计 120 个数据) 用于建立模型, 40*2 组数据 (共计 80 个数据) 用于验证模型。数据集划分采用了 7:1.5:1.5 的方式, 设置 84 个数据 (70%) 为训练集

数据,18个数据(15%)为验证集数据,18个数据(15%)为测试集数据。同时,为了避免过度复杂模型导致的过拟合,根据数据集特点,设置隐含层数量为1。输入层神经元数量为6,输出层神经元数量为2。隐含层神经元数量根据经验公式进行

试算选择^[13],确定为14。最终确定反向传播神经网络(Back propagation neural network, BPNN)模型结构如图3所示,拓扑结构为6-14-2,采用鲸鱼优化算法(Whale optimization algorithm, WOA)优化模型。




图3 BPNN模型结构

Fig. 3 BPNN model structure

2 基础理论

2.1 WOA

WOA是一种模拟座头鲸群体气泡狩猎捕食过程的元启发式算法,如图4(a)所示。WOA的3个阶段^[13]如下:

第一阶段是包围猎物阶段。如图4(b)所示,当鲸鱼发现猎物后,采用9种方式开始包围猎物,鲸鱼根据目标猎物位置或接近目标猎物最近点进行位置更新,位置更新公式为:

$$\vec{G} = \left| C \cdot \vec{X}^*(n) - \vec{X}(n) \right| \quad (4)$$

$$\vec{X}(n+1) = \vec{X}^*(n) - A \cdot \vec{G} \quad (5)$$


$$A = 2 \cdot a \cdot r - a \quad (6)$$

$$C = 2 \cdot r \quad (7)$$


式中: $\vec{G}$ 为包围步长; $\vec{X}(n)$ 为当前鲸鱼位置; $\vec{X}^*(n)$ 为目前获得的最佳位置; n 为当前迭代; A 、 C 为系数向量; a 线性从2到1; r 为 $[0,1]$ 之间的随机数。

第二阶段是捕猎阶段。鲸鱼与猎物之间的距离根据螺旋数学方法得到,鲸鱼趋向最佳位置的更新公式为:

$$\vec{X}(n+1) = e^{bk} \cdot \cos(2\pi k) \cdot \vec{G} + \vec{X}^*(n) \quad (8)$$



(a)气泡网狩猎



(b)螺旋更新位置

图4 WOA示意图

Fig. 4 Schematic diagram of WOA

$$\vec{G}' = |\vec{X}^*(n) - \vec{X}(n)| \quad (9)$$

式中: b 为表示螺旋形状的常数; k 为 $[0, 1]$ 任意数; $\vec{G}'$ 为第 i 条鲸鱼到猎物的位置。

上述捕食模式的概率约为 50%。泡网攻击捕猎阶段的数学模型定义为:

$$\vec{X}(n+1) = \begin{cases} \vec{X}^*(n) - \vec{A} \cdot \vec{G}, p < 0.5 \\ \vec{G}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(n), p \geq 0.5 \end{cases} \quad (10)$$

第三阶段是探索阶段,座头鲸根据彼此的位置随机搜索。搜索猎物的方法基于 A 向量的变化,为避免陷入局部最小值,使 A 的随机值 > 1 或 < -1 来强制搜索代理,根据随机选择的鲸鱼位置来更新探索阶段中其他鲸鱼的位置,而不是根据迄今为止找到的最佳鲸鱼进行位置更新。该阶段强调探索并允许 WOA 进行全局搜索,数学模型如下:

$$\vec{G} = |\vec{C} \cdot \vec{X}_{\text{rand}} - \vec{X}| \quad (11)$$

$$\vec{X}(n+1) = \vec{X}_{\text{rand}} - \vec{A} \cdot \vec{G} \quad (12)$$

式中: $\vec{X}_{\text{rand}}$ 为当前位置中选择的随机向量。

2.2 评价指标

采用相关系数(R)、决定系数(R^2)、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)评价 WOA-BPNN 模型对钢筋混凝土耐久性的预测性能,具体公式如下:

$$R = \frac{\sum_{i=1}^m (y_i - \bar{y}_i) \sum_{i=1}^m (y_i^* - \bar{y}_i^*)}{\sqrt{\sum_{i=1}^m (y_i - \bar{y}_i)^2 \sum_{i=1}^m (y_i^* - \bar{y}_i^*)^2}} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \bar{y}_i^*)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (14)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \bar{y}_i^*| \quad (15)$$

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \bar{y}_i^*|}{y_i} \times 100 \quad (16)$$

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y_i^*)^2} \quad (17)$$

式中: m 为样本的总数; y_i 为钢筋混凝土达到失效的实际时间; y_i^* 为钢筋混凝土达到失效时的预测值; $\bar{y}$ 为真实值对应的平均值; $\bar{y}^*$ 为预测值对应的平均值。

2.3 计算步骤

预测钢筋混凝土耐久性模型的建立有以下 4 个步骤:

步骤 1: 数据集确定,选取影响钢筋混凝土耐久性的配合比设计参数为输入参数,包括水泥、粉煤灰、矿粉、河砂、粗集料的用量与水胶比。以评价钢筋混凝土耐久性的指标 T_1 、 T_2 为输出参数。数据来自本实验获得的 60*2 组数据,用于建立模型。

步骤 2: 模型训练,使用确定的数据集对 BPNN、WOA-BPNN 模型进行训练,并使用 R 对模型预测能力进行初步评估。

步骤 3: 模型评估,以统计参数 R^2 、RMSE、MAPE、MAE 评估 BPNN、WOA-BPNN 模型的预测能力。

步骤 4: 模型验证,选用 40*2 组数据对已建立的 BPNN、WOA-BPNN 模型的稳定性和精度进行验证。

3 结果与讨论

3.1 数据结果分析

图 5 为在盐渍土通电加速环境下不同配比钢筋混凝土达到失效时的耐久性指标 T_1 、 T_2 。

由图 5 可知, T_1 、 T_2 值分布均匀,不存在离群




图 5 耐久性指标

Fig. 5 Durability indicators

值。矿物掺合料的掺量与耐久性指标呈现出显著的非线性关系,因此难以用数学公式准确描述。掺入矿物掺合料的钢筋混凝土耐久性较低的原因主要是:活性矿物掺合料的加入,引起混凝土孔溶液的 pH 值降低^[14],进而导致混凝土内部钢筋表面钝化膜的稳定性、耐腐蚀性下降。此外,由于前期粉煤灰混凝土与矿粉混凝土的水化反应主要依赖于硅酸盐水泥的水化反应^[15],导致二者前期水化程度低于硅酸盐水泥混凝土,因此其密实度低于普通硅酸盐混凝土^[16]。

通过对 T_1 、 T_2 进行主成分分析(Principal component analysis, PCA),得到主成分数量、特征值和累积贡献率的结果如表 4 所示。本研究提取数字的方法采用提取累积贡献率 $>85\%$ 的主成分。主成分数量为 2,主成分按照解释方差的大小递减排列,因此第一个主成分(PC1)包含最大的方差,第二个主成分(PC2)包含次大的方差。各主成分得分根据 PCA 分析软件计算得出,如图 6(a)所示,主成分总得分等于各主成分得分与其贡献率的乘积之和^[17],如图 6(b)所示。图 6 中主成分的综合得分为正或负,正负值仅表示不同配合比钢筋混凝土综合性能的位置,而不表示任何特定配合比钢筋混凝土的性能水平。通过对各主成分综合得分的比较分析,发现 C 组的综合得分最高,为 2.89。因此, C 组是本研究的最佳比例。FS-15 组在矿物掺合料组中综合得分最高,为 0.49。

表 4 主成分数量、特征值和累积贡献率

Table 4 Principal component number, eigenvalue and cumulative contribution rate

主成分数量	特征值	百分比方差/%	累计/%
1	1.991 52	99.575 97	99.575 97
2	0.008 48	0.424 03	100

3.2 相关性分析

图 7 为钢筋混凝土耐久性的相关系数矩阵,反映了混凝土配合比与钢筋混凝土耐久性之间的相关性。在图 7 中,圆形越大说明二者相关性越强,圆形越小说明相关性越低。此外,图中负值表示二者呈负相关,正值表示 2 个参数之间为正相关^[18]。

如图 7 所示,水泥用量与 T_1 、 T_2 的相关性为 0.78、0.78,表明当水泥用量增加,钢筋混凝土的耐久性提高,即提高了混凝土的性能^[19,20]。河砂用量与 T_1 、 T_2 的相关性为 -0.084 、 -0.12 ,粗集料用量与 T_1 、 T_2 的相关性为 -0.66 、 -0.68 ,均为负相关,表明粗集料含量对混凝土性能影响高于河砂,且混




图 6 不同配合比主成分得分
Fig. 6 Principal component scores of different proportions

凝土性能与粗集料含量密切相关,与 Meddah 等^[21]的研究一致;粗集料与 T_1 、 T_2 呈负相关是因为在达到粗集料最佳掺量后,提高粗集料掺量会使混凝土强度下降^[22]。粉煤灰用量与 T_1 、 T_2 的相关性为 -0.28 、 -0.33 ,呈负相关,主要是由于粉煤灰的火山灰反应发生缓慢,粉煤灰替代水泥后,导致混凝土前期强度降低^[23],即混凝土前期性能下降。矿粉用量与 T_1 、 T_2 的相关性为 -0.44 、 -0.41 ,呈负相关,主要是由于矿粉混凝土在前期 $20\text{ }^{\circ}\text{C}$ 标准养护条件下,其水化反应较普通硅酸盐水泥慢^[24]。水胶比与 T_1 、 T_2 的相关性为 -0.26 、 -0.3 ,呈负相关,主要是由于较低的水胶比可以改善混凝土的孔结构,提高混凝土的抗渗透性能,继而提高钢筋混凝土的耐久性。

3.3 模型建立

图 8 为训练阶段、验证阶段、测试阶段与全部 BPNN、WOA-BPNN 模型的输入输出值拟合曲线。

图 8 表明,钢筋混凝土耐久性的输入值与输出值之间存在良好的线性关系。BPNN、WOA-BPNN 模型训练阶段相关系数 R 分别为 0.865、



图 7 相关系数矩阵

Fig. 7 Correlation coefficient matrix




图 8 BPNN 和 WOA-BPNN 模型建立

Fig. 8 Establishment of BPNN and WOA-BPNN model

0.932,验证阶段相关系数分别为0.865、0.943,测试阶段相关系数分别为0.890、0.952,整体模型相关系数分别为0.871、0.934。经过初步对比分析可以看出,WOA-BPNN模型优于未优化的BPNN模型,且整体相关系数 >0.93 。

为了进一步分析上述预测模型,使用统计参数 R^2 、RMSE、MAPE和MAE评价2种模型的准确性与稳定性,上述评价指标5次预测计算结果如图9所示。




图9 模型验证的评价指标

Fig. 9 Evaluation index of model validation

根据图9可知,在训练集中,BPNN与WOA-BPNN模型的决定系数的大小为 $R^2_{\text{WOA-BPNN}} > R^2_{\text{BPNN}}$,均方根误差的大小为 $\text{RMSE}_{\text{WOA-BPNN}} < \text{RMSE}_{\text{BPNN}}$,平均绝对百分比误差的大小为 $\text{MAPE}_{\text{WOA-BPNN}} < \text{MAPE}_{\text{BPNN}}$,平均绝对误差的大小为 $\text{MAE}_{\text{WOA-BPNN}} < \text{MAE}_{\text{BPNN}}$ 。在测试集中,决定系数的大小为 $R^2_{\text{WOA-BPNN}} > R^2_{\text{BPNN}}$,均方根误差的大小为 $\text{RMSE}_{\text{WOA-BPNN}} < \text{RMSE}_{\text{BPNN}}$,平均绝对百分比误差的大小为 $\text{MAPE}_{\text{WOA-BPNN}} > \text{MAPE}_{\text{BPNN}}$,平均绝对误差的大小为 $\text{MAE}_{\text{WOA-BPNN}} < \text{MAE}_{\text{BPNN}}$ 。因此,在本研究中可以初步得出WOA-BPNN模型预测钢筋混凝土耐久性的性能显著高于BPNN模型。

3.4 预测模型验证

为了验证BPNN、WOA-BPNN模型的预测能力,选择40*2组数据验证模型的准确性。2种模型预测 T_1 、 T_2 的误差范围如图10所示。

根据图10可知,BPNN模型预测 T_1 、 T_2 的误差范围为 $-0.167\% \sim 0.247\%$ 、 $-0.093\% \sim 0.210\%$,WOA-BPNN模型预测 T_1 、 T_2 的误差范围为 $-0.207\% \sim 0.179\%$ 、 $-0.131\% \sim 0.134\%$ 。可以看出2种模型的误差 $\leq \pm 0.3\%$,表明其均具有较好的预测能力。




图10 预测结果误差范围

Fig. 10 Error range of prediction results

为了进一步分析2种模型的预测能力,分别计算了其 R^2 、RMSE、MAPE和MAE,计算结果如图11所示,其中图11(a)为 T_1 的评价指标,图11(b)为 T_2 的评价指标。由图11可知, $R^2_{\text{WOA-BPNN}} > R^2_{\text{BPNN}}$, $\text{RMSE}_{\text{WOA-BPNN}} < \text{RMSE}_{\text{BPNN}}$, $\text{MAPE}_{\text{WOA-BPNN}} < \text{MAPE}_{\text{BPNN}}$, $\text{MAE}_{\text{WOA-BPNN}} < \text{MAE}_{\text{BPNN}}$ 。由统计参数结果可知WOA-BPNN模型的预测能力、准确性与稳定性均优于BPNN模型,表明其可以用来对钢筋混凝土的耐久性进行预测。此结果与Tien Bui等^[10]、Shi等^[11]的研究结果一致,表明经




图 11 评价指标

Fig. 11 Evaluation indicators

WOA 优化的 BPNN 模型可以显著提高预测模型的性能。分析认为,经过 WOA 算法优化的 BPNN 模型预测精度要优于未经优化的 BPNN 模型,主要是由于 BPNN 模型初始的权值和阈值通过随机选择获得,导致 BPNN 模型很容易陷入局部最小值^[25];而 WOA 作为一种全局优化算法,可以用于搜索 BPNN 模型初始的权值和阈值,能够更好地避免陷入局部最小值,从而获得全局最优解,提高模型性能^[10,11]。

4 结 论

(1) 根据数据结果分析可知,C 组为最优配合比,FS-15 组为最优矿物掺合料配合比。

(2) 根据相关系数矩阵分析钢筋混凝土与配合比之间的关系,得出水泥用量与 T_1 、 T_2 呈正相关,河砂、粗集料、粉煤灰、矿粉用量及水胶比与 T_1 、 T_2 呈负相关。

(3) 通过比较 BPNN、WOA-BPNN 模型对钢筋混凝土耐久性的预测性能,表明 WOA 可以显著提高 BPNN 模型的预测能力。预测 T_1 指标的均值分别为 $R^2=0.90$ 、 $RMSE=33.92$ 、 $MAPE=0.06$ 、 $MAE=27.31$;预测 T_2 指标的均值分别为 $R^2=0.90$ 、 $RMSE=29.75$ 、 $MAPE=0.04$ 、 $MAE=23.81$ 。

(4) WOA-BPNN 模型结合了 BPNN 强大的模型拟合能力与 WOA 的全局搜索能力,提高了模型的效率,在解决复杂非线性问题时表现出较好的鲁棒性,应用在预测混凝土耐久性能方面具有良好的适用性。

参考文献:

- [1] Ahmed A A, Shakouri M, Trejo D, et al. Effect of curing temperature and water-to-cement ratio on corrosion of steel in calcium aluminate cement concrete [J]. Construction and Building Materials, 2022, 350: No. 128875.
- [2] Wang P, Ke L Y W, Wu H L, et al. Effects of water-to-cement ratio on the performance of concrete and embedded GFRP reinforcement[J]. Construction and Building Materials, 2022, 351: No. 128833.
- [3] Liang Y, Wang L. Effect of water-to-cement ratio on service life of reinforced concrete structures in chloride environment[J]. Structural Concrete, 2021, 22 (5): 2748-2760.
- [4] Kurda R, Silvestre J D, De Brito J, et al. Optimizing recycled concrete containing high volume of fly ash in terms of the embodied energy and chloride ion resistance[J]. Journal of Cleaner Production, 2018, 194: 735-750.
- [5] Qin Y, Guan K, Kou J, et al. Durability evaluation and life prediction of fiber concrete with fly ash based on entropy weight method and grey theory[J]. Construction and Building Materials, 2022, 327: No. 126918.
- [6] Yang R, Yu R, Shui Z, et al. Environmental and economical friendly ultra-high performance-concrete incorporating appropriate quarry-stone powders[J]. Journal of Cleaner Production, 2020, 260: No. 121112.
- [7] 王甲春, 阎培渝. 海洋环境下钢筋混凝土中钢筋锈蚀的概率[J]. 吉林大学学报:工学版, 2014, 44(2): 352-357.

Wang Jia-chun, Yan Pei-yu. Probability of corrosion of steel reinforcement in reinforced concrete in marine environment[J]. Journal of Jilin University(Engineer-

- ing and Technology Edition), 2014, 44(2): 352-357.
- [8] 王鹏辉, 乔宏霞, 冯琼, 等. 氯氧镁涂层钢筋混凝土两重因素耦合作用下的耐久性模型[J]. 吉林大学学报:工学版, 2020, 50(1): 191-201.
- Wang Peng-hui, Qiao Hong-xia, Feng Qiong, et al. Durability modeling of magnesium chloride coated reinforced concrete under two-factor coupling[J]. Journal of Jilin University(Engineering and Technology Edition), 2020, 50(1): 191-201.
- [9] 冯琼, 田浩正, 乔宏霞, 等. 自然暴露与盐雾加速环境下钢筋混凝土劣化规律及等效关系[J]. 吉林大学学报:工学版, 2023, 53(12): 1-12.
- Feng Qiong, Tian Hao-zheng, Qiao Hong-xia, et al. Deterioration law and equivalent relationship of reinforced concrete under natural exposure and salt spray accelerated environment[J]. Journal of Jilin University(Engineering and Technology Edition), 2023, 53(12): 1-12.
- [10] Tien Bui D, Abdullahi M M, Ghareh S, et al. Fine-tuning of neural computing using whale optimization algorithm for predicting compressive strength of concrete[J]. Engineering with Computers, 2021, 37(1): 701-712.
- [11] Shi B, Wang X, Dong Q, et al. Voids prediction beneath cement concrete slabs using a FEM-ANN method[J]. International Journal of Pavement Engineering, 2023, 24(1): No. 2191198.
- [12] 慕儒. 冻融循环与外部弯曲应力、盐溶液复合作用下混凝土的耐久性与寿命预测[D]. 南京: 东南大学材料科学与工程系, 2000.
- Mu Ru. Durability and life prediction of concrete under the composite effect of freezing and thawing cycles with external bending stress and salt solution[D]. Nanjing: Department of Materials Science and Engineering, Southeast University, 2000.
- [13] Nian T, Li J, Li P, et al. Method to predict the interlayer shear strength of asphalt pavement based on improved back propagation neural network[J]. Construction and Building Materials, 2022, 351: No. 128969.
- [14] Giergiczny Z. Fly ash and slag[J]. Cement and Concrete Research, 2019, 124: No. 105826.
- [15] Scrivener K L, Juilland P, Monteiro P J M. Advances in understanding hydration of Portland cement[J]. Cement and Concrete Research, 2015, 78: 38-56.
- [16] Farhan N A, Sheikh M N, Hadi M N S. Investigation of engineering properties of normal and high strength fly ash based geopolymer and alkali-activated slag concrete compared to ordinary Portland cement concrete[J]. Construction and Building Materials, 2019, 196: 26-42.
- [17] Moropoulou A, Polikreti K, Bakolas A, et al. Correlation of physicochemical and mechanical properties of historical mortars and classification by multivariate statistics[J]. Cement and Concrete Research, 2003, 33(6): 891-898.
- [18] Shamsabadi E A, Roshan N, Hadigheh S A, et al. Machine learning-based compressive strength modeling of concrete incorporating waste marble powder[J]. Construction and Building Materials, 2022, 324: No. 126592.
- [19] Rahmani E, Sharbatdar M Kazem, Beygi M H A. A comprehensive investigation into the effect of water to cement ratios and cement contents on the physical and mechanical properties of roller compacted concrete pavement(RCCP)[J]. Construction and Building Materials, 2020, 253: No. 119177.
- [20] Şahin R, Demirboğa R, Uysal H, et al. The effects of different cement dosages, slumps and pumice aggregate ratios on the compressive strength and densities of concrete[J]. Cement and Concrete Research, 2003, 33(8): 1245-1249.
- [21] Meddah M S, Zitouni S, Belâabes S. Effect of content and particle size distribution of coarse aggregate on the compressive strength of concrete[J]. Construction and Building Materials, 2010, 24(4): 505-512.
- [22] Cetin A, Carrasquillo R L. High-performance concrete: Influence of coarse aggregates on mechanical properties[J]. Materials Journal, 1998, 95(3): 252-261.
- [23] Hefni Y, El Zaher Y A, Wahab M A. Influence of activation of fly ash on the mechanical properties of concrete[J]. Construction and Building Materials, 2018, 172: 728-734.
- [24] Barnett S J, Soutsos M N, Millard S G, et al. Strength development of mortars containing ground granulated blast-furnace slag: Effect of curing temperature and determination of apparent activation energies[J]. Cement and Concrete Research, 2006, 36(3): 434-440.
- [25] 曲广雷, 闫宗伟, 郑木莲, 等. 基于神经网络与回归分析的多孔混凝土性能预测[J]. 吉林大学学报:工学版, 2023, 53(9): 1-13.
- Qu Guang-lei, Yan Zong-wei, Zheng Mu-lian, et al. Prediction of porous concrete properties based on neural network and regression analysis[J]. Journal of Jilin University(Engineering and Technology Edition), 2023, 53(9): 1-13.