

引文格式:卜良桃,叶好焰,杜国强,等. 基于 SSA-BP 的孔道压浆料抗压强度预测研究[J]. 建筑科学与工程学报, 2025, 42(3): 115-125.
BU Liangtao, YE Haoyan, DU Guoqiang, et al. Research on prediction of compressive strength of cable grouts based on SSA-BP[J]. Journal of Architecture and Civil Engineering, 2025, 42(3): 115-125.

DOI:10.19815/j.jace.2023.12056

基于 SSA-BP 的孔道压浆料抗压强度预测研究

卜良桃¹, 叶好焰¹, 杜国强², 侯琦³

(1. 湖南大学 土木工程学院, 湖南 长沙 410082; 2. 香港大学 土木工程系, 香港 999077;
3. 湖南宏力土木工程检测有限公司, 湖南 长沙 410082)

摘要:为实现压浆料抗压强度的精准预测,引入麻雀搜索算法(SSA)优化 BP 神经网络的初始权重和阈值;设计并开展了表面硬度法与超声法检测试验,以 108 组试验数据为样本,建立了包含 2 节点输入层、9 节点隐含层与 1 节点输出层的压浆料抗压强度 SSA-BP 神经网络预测模型,与 BP 神经网络、遗传算法(GA)优化后的 BP 神经网络及测强公式预测结果进行对比;探讨了不同输入参数组合对 SSA-BP 模型预测效果的影响。结果表明:相比 BP 模型与 GA-BP 模型,SSA-BP 模型的均方误差(MSE)分别降低了 53.23%与 26.86%,单次训练时间较 GA-BP 模型减少了 34.40%;相比测强公式,预测值与实测值的判定系数 R^2 从 0.937 提高至 0.975, MSE 与平均绝对误差(MAE)分别降低了 19.81%与 7.20%;单一输入参数的 SSA-BP 模型误差精度降低,但仍具备良好的泛化能力;SSA-BP 模型能够较好挖掘输入、输出参数的数据信息,在拟合优度与预测精度方面比传统方法更有优势,可以准确预测压浆料抗压强度,为孔道压浆料性能预测提供了新方法。

关键词:孔道压浆料;麻雀搜索算法;BP 神经网络;抗压强度预测;超声法;表面硬度法

中图分类号: TU528

文献标志码: A

文章编号: 1673-2049(2025)03-0115-11

Research on prediction of compressive strength of cable grouts based on SSA-BP

BU Liangtao¹, YE Haoyan¹, DU Guoqiang², HOU Qi³

(1. College of Civil Engineering, Hunan University, Changsha 410082, Hunan, China;
2. Department of Civil Engineering, The University of Hong Kong, Hong Kong 999077, China;
3. Hunan Hongli Civil Engineering Inspection and Testing Co., Ltd., Changsha 410082, Hunan, China)

Abstract: In order to achieve accurate prediction of compressive strength of grout, sparrow search algorithm (SSA) was introduced to optimize the initial weights and thresholds of BP neural network. Surface hardness method and ultrasonic testing experiments were designed and carried out using 108 sets of test data as samples, and a SSA-BP neural network prediction model for compressive strength of grout containing 2-node input layer, 9-node hidden layer, and 1-node output layer was established. The prediction results were compared with BP neural network, optimized BP neural network by genetic algorithm (GA) and strength measurement formula. The effects of different combinations of input parameters on the prediction effect of SSA-BP model

were discussed. The results show that the mean square error (MSE) of SSA-BP model is reduced by 53.23% and 26.86% compared with BP model and GA-BP model, and the single training time is reduced by 34.40% compared with GA-BP model. Compared to the strength formula, the coefficient of determination R^2 between predicted and measured values is increased from 0.937 to 0.975, and the MSE and mean absolute error (MAE) are decreased by 19.81% and 7.20%, respectively. Although the error accuracy of SSA-BP model with a single input parameter is reduced, it still has good generalization ability. SSA-BP model is able to better mine the data information of input and output parameters, and it is more advantageous than the traditional method in terms of the goodness of fit and prediction accuracy, which can accurately predict the compressive strength of grouts, and it provides a new method for predicting the performance of cable grouts.

Key words: cable grout; sparrow search algorithm; BP neural network; compressive strength prediction; ultrasonic method; surface hardness method

Author resume: BU Liangtao(1963-), male, PhD, professor, E-mail: plt63@hnu.edu.cn.

0 引言

在中国新建公路桥梁中,95%以上采用预应力混凝土结构^[1],其具有自重小、提高构件承载力与耐久性、钢材利用率高与延缓结构裂缝出现等优点^[2]。冯小伟等^[3]研究发现,良好的预应力孔道压浆是预应力混凝土结构质量的重要保证,而孔道压浆料抗压强度是保证孔道压浆优良的先决条件,且与结构的安全性、可靠性与耐久性密切关联。何聪岩^[4]通过试验研究发现,压浆料强度是孔道内钢绞线与压浆料黏结强度表达式的重要组成部分之一。李鑫^[5]通过钢绞线中心拔出试验发现,压浆料强度与拔出力、黏结应力的大小成正比。

施工现场预留的 160 mm×40 mm×40 mm 棱柱体试块先折后压的试验结果是压浆料抗压强度是否达标的唯一参考依据^[6]。调研发现,施工现场留置的试块存在易损坏或丢失的风险,并且有使用过期或劣质压浆料导致其实际强度不满足规范要求的现象。因此,如何对孔道压浆料抗压强度开展现场检测,建立各影响因素与抗压强度之间的非线性映射关系^[7]是当下亟需解决的问题。

马高等^[8]基于 Back-Propagation(BP)算法,建立了 CFRP 约束混凝土抗压强度的神经网络预测模型,发现预测值与试验值的比值接近于 1;构建了双隐含层的 BP 神经网络模型,准确预测了干湿环境下海洋混凝土的抗压强度。Tenza-Abril 等^[9]基于 640 组轻骨料混凝土声速值,研究发现神经网络模型能够较好地建立声速值与抗压强度间的非线性复杂关系。焦莉等^[10]进一步以超声回弹法的回弹

值和声速值为输入参数,建立烧结砖抗压强度的 BP 神经网络模型,发现其平均相对误差率比测强公式降低了 5%。BP 神经网络在混凝土抗压强度预测方面表现良好,但因其初始权重和阈值具有随机性,导致 BP 模型易出现收敛慢、过拟合与陷入局部最优解等问题^[11]。近年来,国内外学者^[12-13]引入遗传算法(Genetic Algorithm, GA)及麻雀搜索算法(Sparrow Search Algorithm, SSA)等优化算法,确定 BP 神经网络的最优初始权重和阈值,进而提高 BP 模型的收敛速度与预测精度。

陈庆等^[14]基于 GA 算法建立了超高性能混凝土抗压强度预测与配合比反向设计的 BP 模型,发现 GA-BP 神经网络的平均相对误差率仅为 BP 神经网络的 30%。周中等^[15]建立泡沫轻质混凝土抗压强度的 GA-BP 预测模型时发现,GA 算法的全局搜索能力较好地弥补了 BP 神经网络的缺陷,使得 GA-BP 模型具备更高的预测精度。Du 等^[16]以回弹值与声速值为输入参数,构建了高性能自密实混凝土抗压强度的 GA-BP 预测模型,发现预测值与实测值的相关系数为 0.979。Xue 等^[17]通过研究发现,麻雀搜索算法在收敛速度、收敛稳定性与收敛精度等方面有更加突出的表现。段妹玲等^[18]将 SSA 算法应用于门控循环单元(GRU)中,构建混凝土抗压强度的 ISSA-GRU 预测模型,发现其均方根误差与平均绝对误差均低于其他机器学习算法预测结果。Wang 等^[19]基于高性能混凝土原材料组分,采用逻辑混沌映射(LC)与非线性惯性权重递减法优化 SSA 算法,建立抗压强度预测模型。LCSSA-BP 模型预测值与实测值的相关系数更接近 1,在混凝

土配合比设计方面有良好应用前景。此外,SSA 算法在加固效果^[20]、碳排放^[21]、边坡失稳^[22]等方面均有广泛的研究与应用。

以上研究成果显示神经网络在混凝土抗压强度预测效果中表现良好,但目前在孔道压浆料抗压强度检测及精准预测方面研究较少。基于此,本文通过表面硬度法与超声法试验获得 108 组数据样本,以里氏硬度值与平测修正声速值为输入参数,引入 SSA 算法优化 BP 神经网络的初始权重和阈值,构建且重复训练压浆料抗压强度的 SSA-BP 预测模型,并与 BP 模型、GA-BP 模型及测强公式的预测效果进行综合对比,分析使用 SSA-BP 模型预测孔道压浆料抗压强度的可行性以及预测精度、收敛速度、鲁棒性与泛化能力等。

1 试验与方法

1.1 试验材料与仪器

1.1.1 试验材料

试验采用 P. O42.5 级普通硅酸盐水泥、碎石(粒径 5~20 mm)、中砂、1×7-15、20-1860 钢绞线、孔道专用压浆料(性能指标见表 1)、洁净水、 $\phi 110$ mm 的 PVC 管。

表 1 孔道压浆料性能指标

Table 1 Performance indicators of cable grouts			
氯离子质量 分数/%	泌水率/%	3~24 h 垂直 膨胀率/%	设计强度/MPa
≤ 0.3	0	0.02~0.05	50~100

1.1.2 试验仪器

试验仪器包括强制式砂浆搅拌机、水泥压浆高速搅拌机、自落式搅拌机、里博 LB220D 型里氏硬度计、ZBL-M520 非金属超声检测仪、YZH-300·10 型恒加载水泥抗折抗压试验机、穿心式液压千斤顶。

1.2 试件制作

孔道压浆料抗压强度决定因素为水灰比,试验前期通过反复试配得到强度为 50、60、70、80、90、100 MPa 的孔道压浆料,含水率分别为 15%、13.5%、12%、10%、8%、6%。根据压浆料抗压强度等级,由 A~F 展开分组,每组设计 3 个 1 200 mm×250 mm×250 mm 混凝土试件,共制作 18 个试件。试件混凝土强度等级统一为 C50,孔道采用 $\phi 110$ mm 的 PVC 管预留,待混凝土强度达到设计强度的 80%,依次进行拆模、钢绞线穿束、张拉、孔道压浆及养护。每组试件对应 6 组(每组 3 个)160 mm×40 mm×40 mm 棱柱体试块,用于先折后压

试验。在混凝土试件浇筑面的前后两个侧面预留 6 个直径 110 mm 的圆形检测窗口(图 1),用于表面硬度法与超声法试验。



图 1 混凝土试件
Fig. 1 Concrete specimens

1.3 试验数据

表面硬度法试验参考《装配整体式混凝土结构检测技术规程》^[23]附录 F,每个圆形检测窗口内的测区尺寸为 60 mm×60 mm,测区内布置 16 个测点(图 2)。剔除 16 个里氏硬度值的 3 个最大值与 3 个最小值,剩余 10 个值取平均值,作为里氏硬度代表值 H 。

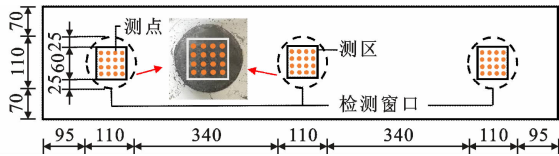


图 2 表面硬度法测点布置(单位:mm)
Fig. 2 Arrangement of measuring points for surface
hardness method (unit:mm)

预应力混凝土结构截面高度最小为 1.2 m^[24],孔道贯穿其中,采用对测法推定压浆料抗压强度操作难度大且成本高昂,只能开展平测法。平测试验测点设计在浇筑面两侧的 6 个检测窗口内(图 3),在同一侧 3 个检测窗口内设计 6 种测距 l ,分别为 420、450、480、870、900、930 mm,记录相应的声时与声速。每个混凝土试件同一测距下得到 2 个声时值与声速值,取其平均值作为该试件声时代表值 T 与声速代表值 V_i 。每组试件对应 6 组棱柱体试块,通过先折后压试验得到 18 个抗压强度值 $f_{cu,i}$,共计 108 组试验数据。

《超声回弹综合法检测混凝土强度技术规程》(T/CECS 02—2005)^[25]中提到,采用平测法检测混凝土抗压强度时,需选取工程某个代表性部位的测距 l 与声时 T 的回归系数修正平测声速值。考虑到单测区修正法精确度低,本文研究引入李秀春等^[26]

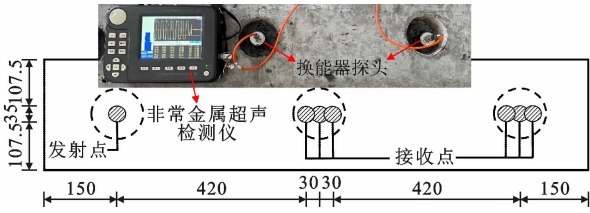


图3 超声法试验(单位:mm)

Fig.3 Ultrasonic test (unit:mm)

提出的全测区声速修正法。每个试件设计为一个测区,将 l 与 T 线性拟合为 $l = a + bT$,回归系数 b 作为拟合对测声速 V_{Dn} 。每组试件 3 个测区拟合对测声速 V_{Dn} 的平均值作为该组试件拟合对测声速代表值 $V_{DM}^{[27]}$ 。平测-对测声速修正系数为 λ ,计算公式见式(1)、(2),平测声速修正值 V_P 计算公式见式(3)。

$$\lambda = \frac{V_{DM}}{V_{iM}} \quad (1)$$

$$V_{DM} = (V_{D1} + V_{D2} + \dots + V_{Dn}) / n \quad (2)$$

$$V_P = \lambda V_i \quad (3)$$

式中: V_{iM} 为每组试件平测声速 V_i 的平均值; V_{Dn} 为每组试件第 n 个测区的拟合对测声速; n 为每组试件测区数量,本文取为 3。

2 神经网络建立及预测

2.1 SSA 算法原理

SSA 算法是模拟麻雀群体捕食与反捕食行为提出的^[28],麻雀群体中包含发现者、加入者与警备者,发现者通常拥有较高的能量储备并且能够搜索到具有丰富食物的区域,为所有的加入者提供觅食方向,警备者占麻雀群体的 10%~20%,负责向群体发送警报信息。利用矩阵 \mathbf{X} 表示有 n 只麻雀的种群,如式(4)所示。

$$\mathbf{X} = \begin{bmatrix} X_{1,1} & X_{1,2} & \dots & X_{1,d} \\ X_{2,1} & X_{2,2} & \dots & X_{2,d} \\ \vdots & \vdots & & \vdots \\ X_{n,1} & X_{n,2} & \dots & X_{n,d} \end{bmatrix} \quad (4)$$

式中: $X_{i,j}$ 为第 i 个麻雀在第 j 维中的位置信息, $i = 1, 2, \dots, n$ 且 $j = 1, 2, \dots, d$, d 为待优化问题的维数,即 BP 神经网络全部神经元对应的权重与阈值数量之和。

在觅食过程中,发现者具有更广泛的搜索范围,它的位置如式(5)移动更新。

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp(-\frac{t}{\alpha i_{\max}}) & R_2 < S \\ X_{i,j}^t + \mathbf{QL} & R_2 \geq S \end{cases} \quad (5)$$

式中: t 为当前迭代次数; i_{\max} 为最大迭代次数; R_2 和 S 分别为预警值和安全值,当 $R_2 \geq S$ 时,表示危险出现,所有麻雀需要移动至安全区域; Q 为服从正态分布的随机数; \mathbf{L} 为一个 $1 \times d$ 的矩阵,该矩阵内全部元素均为 1。

加入者总能搜索并靠近具有最好食物的发现者,在其身边展开觅食,其位置更新按式(6)进行。

$$X_{i,j}^{t+1} = \begin{cases} Q \exp(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}) & i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \mathbf{A}^+ \mathbf{L} & i \leq \frac{n}{2} \end{cases} \quad (6)$$

式中: X_p 为当前发现者占据的最优位置; X_{worst} 为当前种群内最差的位置; \mathbf{A}^+ 为一个 $1 \times d$ 的矩阵,其中每个元素随机赋值为 1 或 -1;当 i 大于 $n/2$ 时,表示适应度较低的第 i 个加入者需要去往位置更好、食物更多的区域获得能量。

当捕食者靠近时,群体边缘的麻雀即为警备者,会迅速向安全区域移动,而中间区域的麻雀会向其他麻雀靠近,降低被捕风险,警备者位置更新如式(7)所示。

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta |X_{i,j}^t - X_{\text{best}}^t| & f_i > f_g \\ X_{i,j}^t + K \frac{|X_{i,j}^t - X_{\text{worst}}^t|}{f_i - f_w + \epsilon} & f_i = f_g \end{cases} \quad (7)$$

式中: X_{best} 为当前种群中最优的位置; β 为服从均值为 0、方差为 1 的正态分布随机数,用于控制步长; K 为麻雀移动方向,是 $[-1, 1]$ 内的随机数; f_i 为当前麻雀个体的适应度值; f_g 和 f_w 为种群内最优和最差的适应度值; ϵ 为最小的常数,以避免分母为 0;当 $f_i > f_g$ 时,表明警备者的位置处于种群边缘,需要向位置最佳的个体移动以免被捕食;当 $f_i = f_g$ 时,表明种群中间位置的个体处于危险状态,需要向其他麻雀个体靠近。

因此,麻雀群体通过不断更新自身位置来寻求全局最优。

2.2 SSA-BP 神经网络模型构建

BP 神经网络是一种多层前馈型网络,包含输入层、隐藏层与输出层,每层包含多个神经元,神经元之间的信息传递通过权重与激励函数来实现,如图 4 所示。图 4 中 x 表示输入参数, ω 表示权重, θ 和 α 表示阈值, y 表示输出参数。BP 神经网络由正向信号传播和反向误差调节构成,信号正向传播时由输入层输入,经隐藏层神经元处理后到达输出层;误差反向调节时按原路径反向计算,过程中连接权值和阈值不断更新,直至 BP 神经网络的输出误差达到

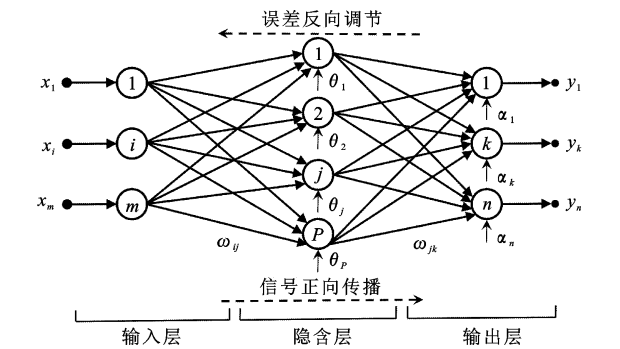


图 4 BP 神经网络结构

Fig. 4 BP neural network structure

预定目标^[28]。

由于 BP 神经网络的初始权重和阈值具有随机性,导致 BP 模型容易陷入局部最优解,出现预测误差偏大、预测精度偏低等问题。因此,引入 SSA 算法优化 BP 神经网络的初始权重和阈值,使其最大限度逼近全局最优解。SSA 算法将最优初始权重和阈值赋予 BP 模型,通过不断迭代与重复训练,直至 BP 神经网络收敛输出。SSA-BP 神经网络模型实施流程如图 5 所示。

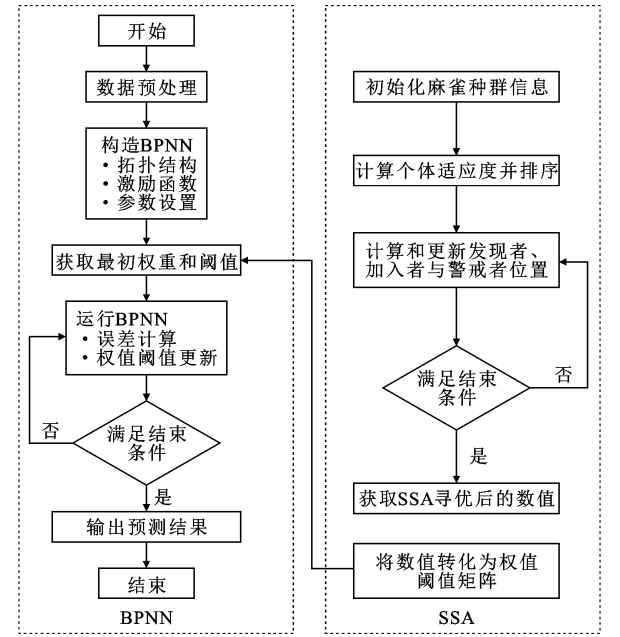


图 5 SSA-BP 模型实施流程

Fig. 5 SSA-BP model implementation process

2.2.1 数据库整理

超声-表面硬度法试验共获得 108 组数据样本,经统计分析得到的方差、标准差、偏度、峰度系数、最大值、最小值与平均值见表 2。试验数据涵盖了大部分可能的情况,里氏硬度 H 在 221~741 HL,平测声速修正值在 $2.99\sim5.79\text{ km}\cdot\text{s}^{-1}$,适用于抗压强度在 $44.6\sim115.8\text{ MPa}$ 的孔道压浆料。所有试

表 2 试验数据统计分析结果

Table 2 Results of statistical analysis of test data

参数	H/HL	$V_p/(\text{km}\cdot\text{s}^{-1})$	$f_{cu,i}/\text{MPa}$
方差	21 216.60	0.91	349.70
标准差	145.66	0.95	18.70
偏度	-0.37	0.14	0.15
峰度系数	2.08	1.43	2.10
最大值	741.00	5.79	115.80
最小值	221.00	2.99	44.60
平均值	512.00	4.31	76.50

验数据在相同的测试条件下使用同一设备测得,消除设备差异、环境因素等造成的测量误差。各试验数据的频率分布直方图如图 6 所示。

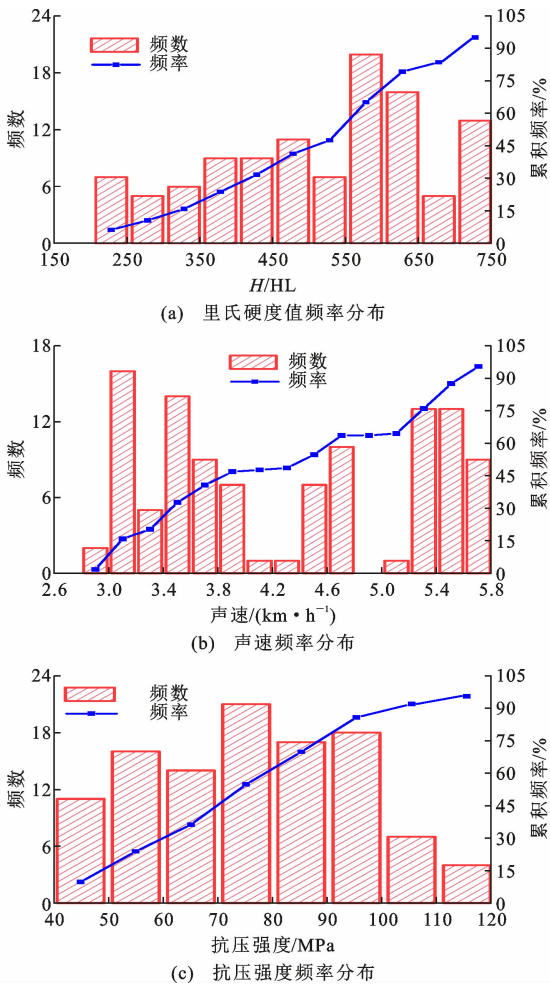


图 6 试验数据频率分布直方图

Fig. 6 Histogram of frequency distribution of test data

2.2.2 数据输入与归一化

本文研究将数据样本划分为训练集(85%)与测试集(15%),以 H 、 V_p 为输入参数,以 $f_{cu,i}$ 为输出参数。考虑到不同参数量纲不同,为保证 SSA-BP 模型的稳定性与收敛速度,根据式(8)对所有变量进行归一化处理。所有输入参数归一化至 $[0,1]$ 范围内,

输出参数归一化至 $[-1,1]$ 范围内。

$$x_i = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (8)$$

式中： x_i 为第 i 个数据归一化后的值； x 为第 i 个数据的原始值； x_{\max} 和 x_{\min} 分别为第 i 个原始数据的最大值与最小值； y_{\max} 和 y_{\min} 分别为数据归一化后值域的最大值和最小值。

2.2.3 算法参数设置

Tenza-Abril 等^[9]研究发现,在工程预测中设置一个隐藏层已足够,但隐藏层中神经元的数量对神经网络模型影响较大。因此,本文将 BP 神经网络的拓扑结构设置为 $2-I_{\text{hid}}-1$,通过经验公式(9)计算得到隐含层节点数 I_{hid} 范围。

$$I_{\text{hid}} = \sqrt{I_{\text{in}} + I_{\text{out}}} + a, a \in [1, 10] \quad (9)$$

式中： I_{in} 为输入层节点数； I_{out} 为输出层节点数。

BP 神经网络的隐含层节点数在 $[2,11]$ 范围内,根据不同隐含层节点数对应的均方误差(MSE),确定最佳隐含层节点数。以 SSA-BP 模型为例,当隐含层节点数为 9 时 MSE 最小(图 7),预测效果最佳,因此本文研究中 SSA-BP 模型拓扑结构为 $2-9-1$ 。

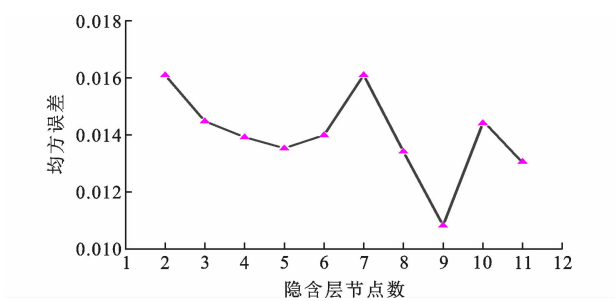


图 7 最佳隐含层节点数

Fig. 7 Optimal number of hidden layer nodes

BP 神经网络中信息的传递依靠权重与激励函数,输入层至隐含层的激励函数设置为 Tansig,隐藏层至输出层的激励函数设置为 Purelin。为保证神经网络的收敛速度,BP 神经网络的训练函数为 Trainlm,采用 Levenberg-Marquardt 训练算法,训练次数为 1 000,学习率为 0.001,训练目标误差为 1×10^{-6} 。

为获取 BP 模型的最优初始权重和阈值,需确定 SSA 算法的最大迭代次数与种群数量。通过 SSA-BP 模型的重复训练发现,当麻雀种群数量为 30 时,模型稳定且预测效果较好。本文研究将抗压强度预测值与实测值的均方根误差(RMSE)作为种群适应度函数,通过适应度的变化确定最大迭代次数。同时引入 GA 算法,比较 SSA 算法与 GA 算法

的全局寻优能力与拟合效果。SSA-BP 与 GA-BP 模型分别迭代至 13 次和 25 次后适应度不再下降(图 8),为确保模型每次运行均能获得优良的适应度,SSA-BP 与 GA-BP 模型最大迭代次数均设置为 30 次。此外,GA 算法的种群数量同 SSA 算法,采用轮盘赌法进行选择操作^[29]。交叉概率常用取值范围为 $[0.25,1]$,变异概率常用取值范围为 $[0.001,0.1]$,通过 GA-BP 模型试错训练发现,当交叉概率为 0.5、变异概率为 0.1 时,GA-BP 模型的预测精度与稳定性最佳。

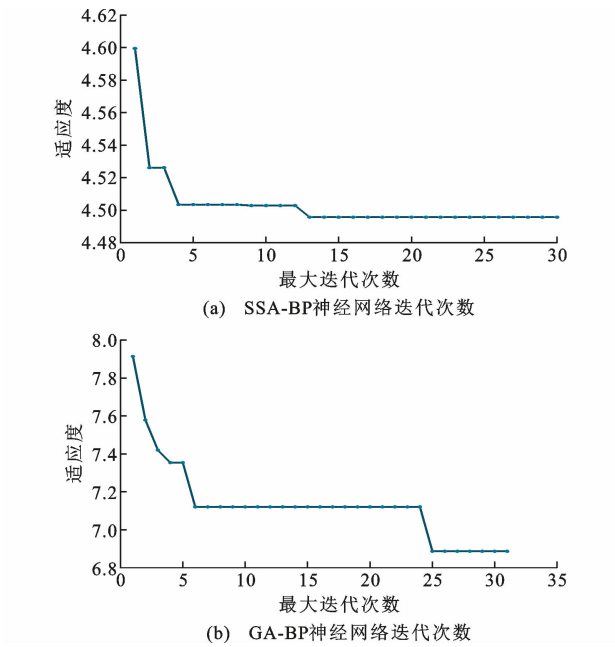


图 8 最大迭代次数

Fig. 8 Maximum number of iterations

2.2.4 神经网络训练与仿真预测

将 SSA 算法全局寻优确认的初始权重和阈值赋予 BP 神经网络,基于 BP 算法对权重和阈值进行迭代与更新,直至 SSA-BP 模型预测误差满足目标要求,停止训练。以均方误差 MSE、均方根误差 RMSE、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、判定系数 R^2 为评价依据,选取最佳的 SSA-BP 模型对孔道压浆料抗压强度进行仿真预测。

3 预测结果与分析

3.1 神经网络模型评价参数

为评价不同神经网络模型的预测效果,引入 $MSE(\sigma_{MSE})$ 、 $RMSE(\sigma_{RMSE})$ 、 $MAE(\sigma_{MAE})$ 、 $MAPE(\sigma_{MAPE})$ 与 R^2 这 5 个参数,如公式(10)~(14)所示。 MSE 、 $RMSE$ 和 MAE 可以反映误差范围,其中

MAE 可以避免误差相互抵消,更真实地反映误差大小;MAPE 反映神经网络模型的预测偏差。当 R^2 越接近 1,MSE、RMSE、MAE、MAPE 越小,说明神经网络模型预测效果越好。

$$\sigma_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

(10)

$$\sigma_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

(11)

$$\sigma_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

(12)

$$\sigma_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\%$$

(13)

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

(14)

式中: \hat{y}_i 、 y_i 分别为抗压强度的预测值与实际值; \bar{y} 为抗压强度实测值的平均值; n 为样本数量。

3.2 神经网络模型预测结果分析

重复训练 SSA-BP 模型、GA-BP 模型及 BP 模型至稳定状态,对测试集样本展开预测,评价参数如表 3 所示。与 BP 模型相比,SSA-BP 模型的 MSE 与 MAE 分别降低了 53.23%与 31.23%;相比 GA-BP 模型,SSA-BP 模型的 MSE 与 MAE 分别降低了 26.86%与 14.32%,SSA-BP 模型预测精度更高。压浆料抗压强度预测值与实测值如图 9 所示,可以看出 SSA-BP 模型测试集所有预测值的偏差均在 10%以内(图 9 中两条虚线之间的点),判定系数 R^2 为 0.982,预测效果较好。抗压强度预测值与实测值的绝对误差率如图 10 所示,SSA-BP 模型的平均绝对误差仅为 2.7 MPa,较 BP 模型与 GA-BP 模型分别降低了 34.38%与 19.84%,因此 SSA-BP 模型更稳定,能够更好地挖掘输入、输出参数的数据信息。

表 3 神经网络模型评价参数

评价参数	BP 模型	GA-BP 模型	SSA-BP 模型
MSE	24.8	15.9	11.6
RMSE	5.0	4.0	3.4
MAE	4.1	3.4	2.8
MAPE/%	5.32	4.90	3.67
R^2	0.964	0.972	0.982
最大绝对误差/MPa	12.0	7.8	8.0
最小绝对误差/MPa	0.4	0.4	0.7
平均绝对误差/MPa	4.1	3.4	2.7

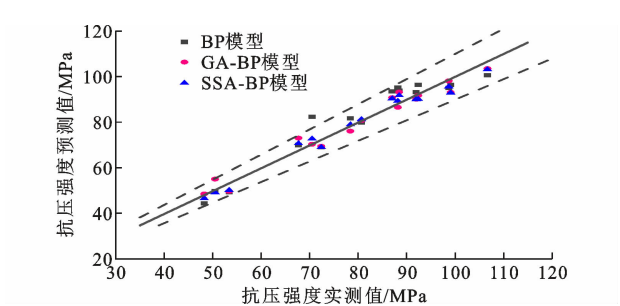


图 9 测试集抗压强度实测值与预测值
Fig. 9 Measured and predicted values of test set compressive strength

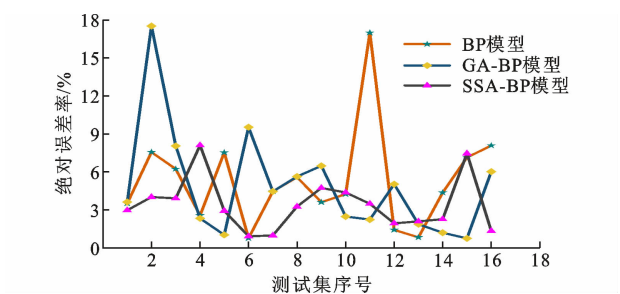


图 10 测试集实测值与预测值的绝对误差率
Fig. 10 Absolute error rate between measured and predicted values of test set

SSA-BP 模型与 GA-BP 模型的单次训练时间分别为 91 s 和 139 s。相比 GA-BP 模型,SSA-BP 模型单次训练时间降低了 34.40%,训练效率更高,在实际复杂问题解决中可以大幅节省时间成本。

3.3 神经网络模型与测强公式预测结果比较

利用 H 、 V_p 和 $f_{cu,i}$,拟合得到超声-表面硬度法测强公式,如公式(15)所示。该拟合公式的判定系数 $R^2=0.937$,平均相对误差 $\delta=4.75\%\leq 10\%$,相对标准差 $e_r=0.35\%\leq 12\%$,满足规范要求。平均相对误差与相对标准差计算公式可参考文献[25]。

$$f'_{cu,i} = 3.06V_p^{0.602} H^{0.375}$$

(15)

式中: $f'_{cu,i}$ 为孔道压浆料按测强公式换算得到的抗压强度推定值。

进一步比较神经网络模型与测强公式的预测精度,应用 SSA-BP 模型、GA-BP 模型及 BP 模型对全体数据样本展开仿真预测,预测结果如表 4 所示。与测强公式相比,SSA-BP 模型的预测效果优势显著, R^2 从 0.937 提高至 0.975。通过抗压强度预测值与实测值线性拟合(图 11)发现,测强公式与 SSA-BP 模型拟合直线斜率分别为 0.943 与 0.968,斜率越接近 1,抗压强度预测值更贴近实测值。与 BP 模型、GA-BP 模型相比,SSA-BP 模型的 MSE 分别降低了 12.12%与 7.47%,在全体样本仿真预

表 4 全体样本预测结果评价参数

Table 4 Evaluation parameters of prediction results of whole sample

评价参数	BP 模型	GA-BP 模型	SSA-BP 模型	测强公式
MSE	19.7	18.7	17.3	21.6
MAE	3.4	3.4	3.4	3.6
MAPE/%	4.49	4.48	4.29	4.75
R^2	0.971	0.974	0.975	0.937
抗压强度最大误差/MPa	13.2	13.4	12.2	14.7
抗压强度最小误差/MPa	0.2	0.2	0.2	0.2
抗压强度平均误差/MPa	3.4	3.4	3.3	6.0

测中拟合效果最佳。

比较测强公式与 SSA-BP 模型在全体样本中预测值与实测值的误差发现,平均绝对误差分别为6.0 MPa 和 3.3 MPa,最大误差率分别为 12.65% 和 11.76%,分别降低了 43.69% 与 7.0%;SSA-BP 模型的 MSE 与 MAE 分别降低了 19.81% 与 7.20%,SSA-BP 模型在仿真预测中更稳定(图 12)。

3.4 其他 SSA-BP 神经网络模型

孔道压浆料抗压强度检测时因检测窗口尺寸受限,只能开展表面硬度法,或因检测面有气泡、裂纹等缺陷,只能开展超声法。因此,改变输入参数组合,建立 SSA-BP- H 与 SSA-BP- V_p 神经网络模型,通过反复训练得到模型的拓扑结构与评价结果,如表 5 所示。单一输入参数的 SSA-BP 模型预测精度降低,建议实际工程中检测压浆料抗压强度时同时采用表面硬度法与超声法。

以 SSA-BP- H 模型为例,参考赵建华等^[30-31]套筒灌浆料抗压强度检测的试验结果,开展仿真预测,验证 SSA-BP 模型的泛化能力。比较抗压强度实测值、SSA-BP- H 模型预测值与测强公式预测值,MSE、RMSE、MAE 及 R^2 等评价结果见表 6。

由于文献[30]中未提供具体测强公式,只有 R^2 唯一评价结果。应用 SSA-BP- H 模型开展仿真预测,灌浆料抗压强度预测值与实测值的 R^2 分别从 0.871、0.906 提高至 0.983、0.942;文献[30]、[31] 的 SSA-BP 模型抗压强度预测值与实际值比值的平均值分别为 0.940 与 0.978。相比测强公式,SSA-BP- H 模型更好地反映了里氏硬度值与抗压强度间的非线性映射关系。灌浆料抗压强度预测结果如图 13 所示。

统计灌浆料抗压强度预测值与实测值绝对误差

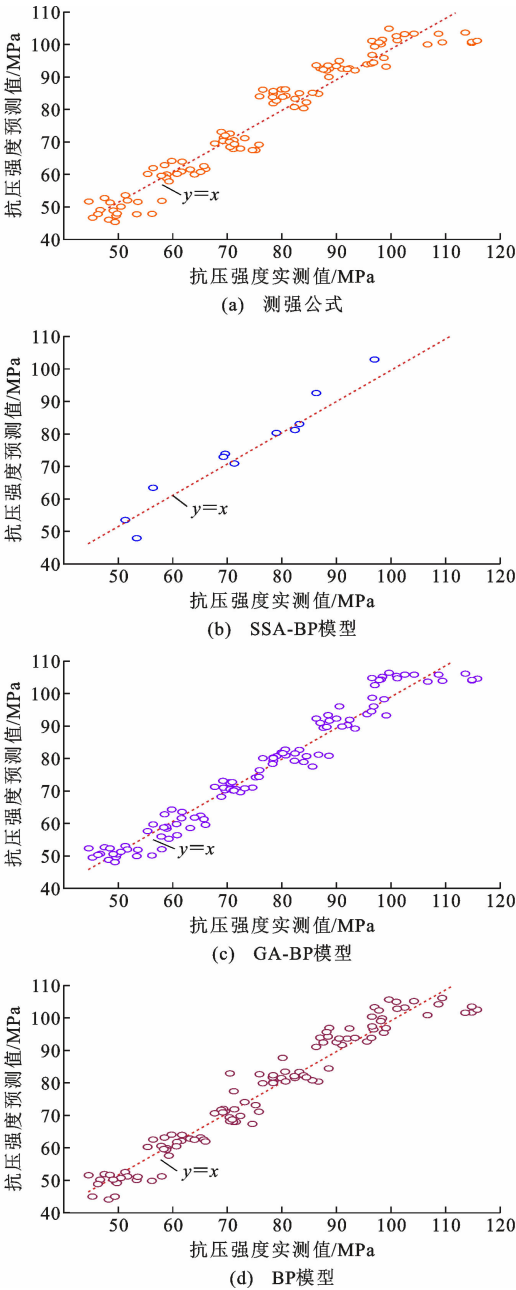


图 11 全体样本抗压强度实测值与预测值

Fig. 11 Measured and predicted compressive strength of whole sample

率在 10% 以内的占比,文献[30]、[31] 的 SSA-BP 模型与测强公式(文献[31])的占比分别为 93%、67% 与 54%,MAPE 分别为 7.31%、8.88% 与 9.49%。与测强公式相比,SSA-BP 模型的预测精度提高了 17.81%,最大误差率与平均误差率分别降低了 25.85% 与 6.41%,因此 SSA-BP 模型鲁棒性更好。

4 结 语

(1)为精准预测孔道压浆料抗压强度,本文基于

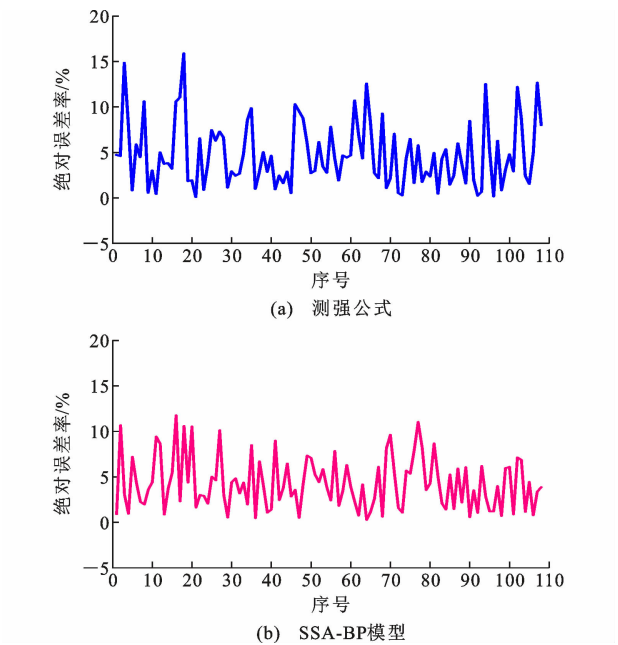


图 12 SSA-BP 模型与测强公式全体样本绝对误差率

Fig. 12 Absolute error rates of SSA-BP model and intensity measurement formula for whole sample

表 5 其他神经网络模型评价参数

Table 5 Other neural network model evaluation parameters

输入参数	拓扑结构	MAE	RMSE	R^2
H	1-7-1	3.3	4.6	0.967
V_P	1-11-1	3.6	4.9	0.965

表 6 SSA-BP-H 模型预测结果评价参数

Table 6 Evaluation parameters of SSA-BP-H model prediction results

评价参数	SSA-BP 模型 (文献[30])	文献[30]	SSA-BP 模型 (文献[31])	测强公式 (文献[31])
MSE	34.9		48.3	56.9
RMSE	5.9		7.0	7.5
MAE	5.5		5.8	5.9
MAPE/%	7.31		8.88	9.49
R^2	0.983	0.871	0.942	0.906

表面硬度法与超声法试验,以里氏硬度值与平测修正声速值为输入参数,建立了拓扑结构为 2-9-1 的 SSA-BP 神经网络预测模型,预测效果优势显著。

(2)与 BP 模型、GA-BP 模型相比,SSA-BP 模型预测精度分别提高了 53.23%与 26.86%,预测值与实测值的 R^2 更接近 1。同时,SSA-BP 模型单次训练时间较 GA-BP 模型减少了 48 s,能够大幅降低时间成本。

(3)与超声-表面硬度法测强公式相比,SSA-BP 模型对全体样本进行仿真预测的 R^2 从 0.937 提高至 0.975,平均绝对误差降低了 43.69%,预测精度

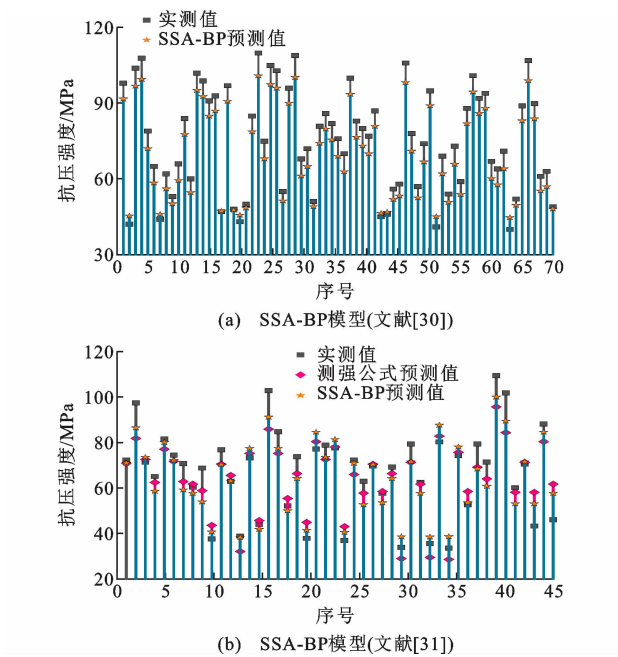


图 13 SSA-BP-H 模型预测值与实测值比较

Fig. 13 Comparison of predicted and measured values of SSA-BP-H model

及鲁棒性较传统方法更有优势。

(4)改变输入参数组合建立了 2 种其他 SSA-BP 模型,基于既有文献试验数据发现,SSA-BP 模型具备良好的泛化能力,能够更好反映各变量之间的非线性映射关系。

参考文献:

References:

[1] 密士文,朱自强,彭凌星,等. T 梁预应力波纹管压浆密度超声检测试验研究[J]. 中南大学学报(自然科学版),2013,44(6):2378-2384.

MI Shiwen, ZHU Ziqiang, PENG Lingxing, et al. Experimental study of detecting grouting density of pre-stressed tendon ducts through ultrasonic [J]. Journal of Central South University (Science and Technology), 2013, 44(6): 2378-2384.

[2] 邵旭东,曹君辉. 面向未来的高性能桥梁结构研发与应用[J]. 建筑科学与工程学报,2017,34(5):41-58.

SHAO Xudong, CAO Junhui. Research and application of high performance bridge structures toward future[J]. Journal of Architecture and Civil Engineering, 2017, 34(5): 41-58.

[3] 冯小伟,毛云程. 预应力孔道压浆试件破坏的力学性能分析[J]. 混凝土,2014(1):155-158.

FENG Xiaowei, MAO Yuncheng. Mechanics property analysis on specimen damage of the prestressed duct grouting[J]. Concrete, 2014(1): 155-158.

- [4] 何聪岩. 波纹管内钢绞线粘结性能试验与理论研究[D]. 天津: 河北工业大学, 2021.
HE Congyan. Theoretical and experimental research on bonding performance of steel strand in corrugated pipe[D]. Tianjin: Hebei University of Technology, 2021.
- [5] 李鑫. 核电用预应力钢绞线粘结滑移性能和锚固长度研究[D]. 大连: 大连理工大学, 2020.
LI Xin. Study on bond-slip properties and anchorage length of prestressing strand used in nuclear power plant[D]. Dalian: Dalian University of Technology, 2020.
- [6] 公路桥涵施工技术规范: JTG/T 3650—2020[S]. 北京: 人民交通出版社, 2020.
Technical specifications for construction of highway bridges and culverts: JTG/T 3650—2020[S]. Beijing: China Communications Press, 2020.
- [7] 张竞男, 孙福洋, 王浩. 基于 BP 神经网络的超声-回弹-钻芯综合测强法[J]. 建筑科学与工程学报, 2009, 26(1): 68-74.
ZHANG Jingnan, SUN Fuyang, WANG Hao. Ultrasonic-rebound and core-drilling synthetic method in strength testing based on BP neural network[J]. Journal of Architecture and Civil Engineering, 2009, 26(1): 68-74.
- [8] 马高, 刘康. 基于 BP 神经网络 CFRP 约束混凝土抗压强度预测[J]. 湖南大学学报(自然科学版), 2021, 48(9): 88-97.
MA Gao, LIU Kang. Prediction of compressive strength of CFRP-confined concrete columns based on BP neural network[J]. Journal of Hunan University (Natural Sciences), 2021, 48(9): 88-97.
- [9] TENZA-ABRIL A J, VILLACAMPA Y, SOLAK A M, et al. Prediction and sensitivity analysis of compressive strength in segregated lightweight concrete based on artificial neural network using ultrasonic pulse velocity[J]. Construction and Building Materials, 2018, 189: 1173-1183.
- [10] 焦莉, 刘明, 李宏男. 利用改进的 BP 神经网络预测烧结砖的抗压强度[J]. 建筑材料学报, 2005, 8(3): 284-288.
JIAO Li, LIU Ming, LI Hongnan. Forecast about the compressive strength of clay brick based on improved BP neural network[J]. Journal of Building Materials, 2005, 8(3): 284-288.
- [11] KEWALRAMANI M A, GUPTA R. Concrete compressive strength prediction using ultrasonic pulse velocity through artificial neural networks[J]. Automation in Construction, 2006, 15(3): 374-379.
- [12] JIN L B, DUAN J, FAN T, et al. Using GA-BP coupling algorithm to predict the high-performance concrete mechanical property[J]. KSCE Journal of Civil Engineering, 2023, 27(2): 684-697.
- [13] CHEN G, ZHU D L, WANG X, et al. Prediction of concrete compressive strength based on the BP neural network optimized by random forest and ISSA[J]. Journal of Function Spaces, 2022, 2022: 8799429.
- [14] 陈庆, 马瑞, 蒋正武, 等. 基于 GA-BP 神经网络的 UHPC 抗压强度预测与配合比设计[J]. 建筑材料学报, 2020, 23(1): 176-183, 191.
CHEN Qing, MA Rui, JIANG Zhengwu, et al. Compressive strength prediction and mix proportion design of UHPC based on GA-BP neural network[J]. Journal of Building Materials, 2020, 23(1): 176-183, 191.
- [15] 周中, 邓卓湘, 陈云, 等. 基于 GA-BP 神经网络的泡沫轻质土强度预测[J]. 华南理工大学学报(自然科学版), 2022, 50(11): 125-132.
ZHOU Zhong, DENG Zhuoxiang, CHEN Yun, et al. Strength prediction of foam light soil based on GA-BP neural network[J]. Journal of South China University of Technology (Natural Science Edition), 2022, 50(11): 125-132.
- [16] DU G Q, BU L T, HOU Q, et al. Prediction of the compressive strength of high-performance self-compacting concrete by an ultrasonic-rebound method based on a GA-BP neural network[J]. PLOS One, 2021, 16(5): e0250795.
- [17] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [18] 段妹玲, 张单, 袁锦虎, 等. 基于 ISSA-GRU 的混凝土抗压强度预测[J]. 硅酸盐通报, 2023, 42(7): 2392-2400.
DUAN Meiling, ZHANG Dan, YUAN Jinhu, et al. Prediction of compressive strength of concrete based on ISSA-GRU[J]. Bulletin of the Chinese Ceramic Society, 2023, 42(7): 2392-2400.
- [19] WANG K W, REN J, YAN J W, et al. Research on a concrete compressive strength prediction method based on the random forest and LCSSA-improved BP neural network[J]. Journal of Building Engineering, 2023, 76: 107150.
- [20] LI G B, HU T Y, BAI D W. BP neural network improved by sparrow search algorithm in predicting

- debonding strain of FRP-strengthened RC beams[J]. *Advances in Civil Engineering*, 2021, 2021(1): 9979028.
- [21] 王庆荣,王俊杰,朱昌锋,等.融合VMD和SSA-LSSVM的交通运输业碳排放预测研究[J]. *环境工程*, 2023, 41(10): 124-132.
WANG Qingrong, WANG Junjie, ZHU Changfeng, et al. Carbon emission prediction of transportation industry based on VMD and SSA-LSSVM[J]. *Environmental Engineering*, 2023, 41(10): 124-132.
- [22] 金爱兵,张静辉,孙浩,等.基于SSA-SVM的边坡失稳智能预测及预警模型[J]. *华中科技大学学报(自然科学版)*, 2022, 50(11): 142-148.
JIN Aibing, ZHANG Jinghui, SUN Hao, et al. Intelligent prediction and alert model of slope instability based on SSA-SVM[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2022, 50(11): 142-148.
- [23] 装配整体式混凝土结构检测技术规程: DB32/T 3754—2020[S]. 南京:江苏科学技术出版社, 2020.
Technical specification for testing of assembled monolithic concrete structures: DB32/T 3754—2020[S]. Nanjing: Jiangsu Science and Technology Press, 2020.
- [24] 吴瑞. 桥梁预应力管道灌浆密实度综合检测试验研究[D]. 成都:西华大学, 2019.
WU Rui. Experimental study on comprehensive test of grouting density of bridge prestressed pipeline in bridge[D]. Chengdu: Xihua University, 2019.
- [25] 超声回弹综合法检测混凝土强度技术规程: CECS 02—2005[S]. 北京:中国计划出版社, 2005.
Technical specification for detecting strength of concrete by ultrasonic-rebound combined method: CECS 02—2005[S]. Beijing: China Planning Press, 2005.
- [26] 李秀春,邓亚,张春良,等.超声回弹综合法检测混凝土结构强度平测修正方法技术研究[J]. *建筑结构*, 2019, 49(增1): 875-877.
LI Xiuchun, DENG Ya, ZHANG Chunliang, et al. Technology research on the method of ultrasonic-rebound synthesis method for testing concrete structure strength[J]. *Building Structure*, 2019, 49(S1): 875-877.
- [27] 吴楠,韩爱民,孙春霞,等.超声回弹法平测声速修正系数计算及可靠性检验[J]. *中外公路*, 2008, 28(5): 243-246.
WU Nan, HAN Aimin, SUN Chunxia, et al. Calculation and reliability test of correction coefficient for flat measurement of sound velocity by ultrasonic rebound method[J]. *Journal of China & Foreign Highway*, 2008, 28(5): 243-246.
- [28] 薛建凯. 一种新型的群智能优化技术的研究与应用: 麻雀搜索算法[D]. 上海:东华大学, 2020.
XUE Jiankai. Research and application of a new swarm intelligence optimization technology: sparrow search algorithm[D]. Shanghai: Donghua University, 2020.
- [29] 王双双. 基于GABP神经网络的智能变电站成熟度模型构建及评价研究[D]. 郑州:郑州大学, 2020.
WANG Shuangshuang. Maturity model establishment and evaluation of smart substation based on GABP neural network[D]. Zhengzhou: Zhengzhou University, 2020.
- [30] 赵建华,凌良建,吕嘉,等.表面硬度法检测灌浆料实体强度试验研究[J]. *混凝土与水泥制品*, 2022(8): 78-82.
ZHAO Jianhua, LING Liangjian, LYU Jia, et al. Experimental study on testing solid strength of grouting materials by surface hardness method[J]. *China Concrete and Cement Products*, 2022(8): 78-82.
- [31] 吴玉龙,顾盛,赵建华,等.基于孔道条件的表面硬度法检测灌浆料抗压强度试验研究[J]. *混凝土*, 2022(3): 186-192.
WU Yulong, GU Sheng, ZHAO Jianhua, et al. Experimental study on testing compressive strength of grouting material by surface hardness method based on pore condition[J]. *Concrete*, 2022(3): 186-192.