

引文格式:王海英,李子彤,张英治,等.基于拌和生产数据的 BP 神经网络混凝土抗压强度预测[J].建筑科学与工程学报,2024,41(3):18-25.

WANG Haiying, LI Zitong, ZHANG Yingzhi, et al. BP neural network prediction of concrete compressive strength based on mixing production data[J]. Journal of Architecture and Civil Engineering, 2024, 41(3): 18-25.

DOI:10.19815/j.jace.2023.12082

# 基于拌和生产数据的 BP 神经网络混凝土抗压强度预测

王海英<sup>1</sup>, 李子彤<sup>1</sup>, 张英治<sup>2</sup>, 王晨光<sup>1</sup>

(1. 长安大学 工程机械学院, 陕西 西安 710064; 2. 陕西交通控股集团有限公司, 陕西 西安 710075)

**摘要:**为解决混凝土生产中抗压强度试验周期长及工程管理存在滞后性的问题,提出了一种基于混凝土拌和生产实时监控数据的 BP 神经网络混凝土抗压强度预测模型。以混凝土拌和生产中的 8 项物料生产称重数据和 5 项生产配比数据作为预测输入变量,建立 200 组混凝土拌和站生产监控数据和对应的抗压强度试验数据样本集,按照 6:2:2 比例划分为训练集、验证集和测试集;分别以 C40 配比混凝土拌和生产的 8 项物料称重数据和全部 13 项数据作为输入变量,进行混凝土 28 d 抗压强度预测,将预测结果与实际试验结果进行比较,验证所提出 BP 神经网络模型的预测效果。结果表明:所提出的 BP 神经网络混凝土强度预测模型能较好地实时预测混凝土 28 d 抗压强度,且相对误差优于利用 7 d 抗压强度试验数据估算值;8 项物料称重数据作为输入变量的 BP 神经网络预测模型预测精度更好,平均绝对百分比误差为 0.82%,均方根误差为 0.52 MPa;利用不同拌和站 C20 配比、C30 配比混凝土拌和生产监控数据对 8 项输入变量 BP 神经网络混凝土抗压强度预测模型进行适应性验证可知,其预测平均绝对误差均在 0.5 MPa 之内,平均绝对百分比误差均小于 2%,与 C40 配比预测误差一致;该预测模型充分挖掘了混凝土拌和站生产实时监控数据的价值,实现了传统混凝土抗压试验结果提前化,对提高工程建设质量水平具有重要意义。

**关键词:**混凝土;预测模型;BP 神经网络;抗压强度;拌和生产监控数据

中图分类号:U415.12

文献标志码:A

文章编号:1673-2049(2024)03-0018-08

## BP neural network prediction of concrete compressive strength based on mixing production data

WANG Haiying<sup>1</sup>, LI Zitong<sup>1</sup>, ZHANG Yingzhi<sup>2</sup>, WANG Chenguang<sup>1</sup>

(1. School of Construction Machinery, Chang'an University, Xi'an 710064, Shaanxi, China;

2. Shaanxi Transportation Holding Group Co., Ltd., Xi'an 710075, Shaanxi, China)

**Abstract:** In order to solve the problems of long testing period and lagging of project management in concrete production, a BP neural network model for predicting concrete compressive strength based on real-time monitoring data of concrete mixing production was proposed. Taking the 8 items of material production weighing data and 5 items of production mixing ratio data in concrete mixing production as input variables, 200 sets of production monitoring data and test data sample

sets were established, which were divided into training set, verification set, and test set according to the ratio of 6 : 2 : 2. The 8 items of material weighing data and all 13 items of data of C40 ratio concrete mixing and production were used as input variables for 28 d compressive strength prediction of concrete, and the predicted results were compared with the actual test results to verify the effectiveness of the proposed BP neural network prediction model. The results show that the proposed BP neural network concrete strength prediction model can effectively predict the 28 d compressive strength of concrete in real time, and the prediction relative error is better than the estimated value using 7 d compressive strength test data. The BP neural network prediction model with 8 items of material weighing data as input variables has better prediction accuracy, with a mean absolute percentage error of 0.82% and a root mean square error of 0.52 MPa. Furthermore, the adaptability of the BP neural network concrete compressive strength prediction model with 8 items of input variables is verified using production monitoring data of C20 and C30 ratios from different mixing stations, and the prediction mean absolute errors are within 0.5 MPa, and the average absolute percentage errors are less than 2%, consistent with the prediction errors of C40 ratio. The prediction model fully explores the value of real-time monitoring data of concrete mixing station production, realizes the advance of the traditional concrete compressive test results, and has important practical significance for improving the quality level of engineering construction.

**Key words:** concrete; prediction model; BP neural network; compressive strength; production monitoring data

**Author resume:** WANG Haiying (1971-), female, PhD, associate professor, E-mail: whying@chd.edu.cn.

## 0 引言

混凝土抗压强度是确定混凝土强度等级的重要参数,同时也是对比和评价混凝土力学性能的重要指标<sup>[1]</sup>。用于抗压强度试验的混凝土试件需要养护28 d后进行试验,根据试验结果判断该批次混凝土应用于主体工程的强度等级是否合格。因此,从混凝土生产到试验存在着时间滞后问题,工程质量管理也会因混凝土不合格引起拆除和返工,造成工程造价的提高。

为了解决试验结果滞后导致的工程质量管理问题,通常利用混凝土试件7 d抗压强度试验结果达到70%设计强度估算试件28 d抗压强度达到100%设计强度进行施工管理。许多学者提出了利用混凝土生产配比试验数据进行抗压强度预测的方法,主要有多元自适应回归曲线法<sup>[2]</sup>、代价敏感系数法<sup>[3]</sup>、BP神经网络法<sup>[4]</sup>、FLR和ANFIS结合法<sup>[5]</sup>、随机森林算法<sup>[6]</sup>及深度学习法<sup>[7]</sup>。学者们通过对预测模型的输入变量进行选择确定,验证了不同方法的预测效果。Zhu等<sup>[8]</sup>提出了一种基于灰色关联分析的再生骨料混凝土抗压强度预测方法,解释了水

灰比及骨料掺量对再生骨料混凝土抗压强度的影响关系。陈庆等<sup>[9-12]</sup>以水胶比、硅灰量、集料量及水泥、粉煤灰等试验配比数据作为输入变量,验证了BP神经网络、海豚伙伴算法优化BP神经网络、GA-BP神经网络模型的混凝土抗压强度预测效果。Feng等<sup>[13]</sup>以粗骨料、细骨料、水泥、水、外加剂等试验配比和养护时间作为输入变量,验证了AdaBoost算法预测混凝土抗压强度的可行性。Al-Jamimi等<sup>[14]</sup>以普通硅酸盐水泥(OPC)、硅灰(SF)、粉煤灰(FA)、水泥含量和含水量等作为自变量,建立了支持向量机(SVM)和遗传算法(GA)的混合预测模型,并验证了混凝土抗压强度预测的有效性。Ma等<sup>[15-17]</sup>以水胶比、水泥用量、煤矸石粉量、锂渣掺量、减水剂掺量以及粗细集料量等生产数据作为输入变量,验证了因子分析法优化BP神经网络模型、多元回归预测模型和自适应神经模糊推理系统对石粉混凝土、锂渣混凝土和硅灰的抗压强度预测效果。Cui等<sup>[18]</sup>提出了基于Boosting树算法的XGBoost混凝土抗压强度预测模型,并与现有的7种机器学习预测方法进行了预测效果对比。

上述研究中的输入数据样本均基于配比试验数

据,但实际生产时,物料的投放量及生产配比与设计值存在偏差,导致预测数据的误差增大。如何利用实际拌和生产数据进行混凝土抗压强度预测需要进一步研究。因此,本文提出了一种基于混凝土拌和生产实时监控数据的 BP 神经网络混凝土抗压强度预测模型,优选预测模型的输入变量,对模型的预测精度和适用性进行验证,为工程质量管理提供有效参考。

# 1 BP 神经网络混凝土抗压强度预测模型

## 1.1 数据来源

拌和站生产实时监控数据包括 8 项生产称重数据[水泥、水、碎石 1(粒径 16~31.5 mm)、碎石 2(粒径 10~20 mm)、碎石 3(粒径 5~10 mm)、河砂、粉煤灰、减水剂]和 5 项配比数据(胶凝材料、粗细集料、水胶比、水灰比和砂率)。分别以 8 项生产称重数据和全部 13 项生产数据作为输入变量,以该混凝土 28 d 抗压强度试验数据作为输出变量,进行 BP 神经网络混凝土抗压强度预测模型的训练和验证。

## 1.2 预测模型构建

BP 神经网络预测是一种基于误差反向传播算法的多层前馈型神经网络,模型中信号正向传播,误差反向传播。在前向传播过程中,输入信号来源于输入层,经过隐藏层逐层传播,最后在输出层终止输入信号。每层神经元的状态只影响下一层神经元的状态。如果输出层不能得到期望的输出,则进行反向传播,根据预测的误差值调整网络权重或阈值。

本文提出的 BP 神经网络混凝土抗压强度预测模型如图 1 所示,模型输入层变量为混凝土拌和生产实时监控数据,输出层变量为混凝土抗压强度。

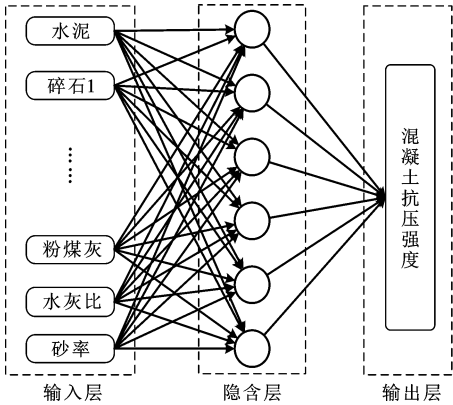


图 1 BP 神经网络混凝土抗压强度预测模型

Fig. 1 BP neural network concrete compressive strength prediction model

模型的计算流程如图 2 所示,具体步骤为:

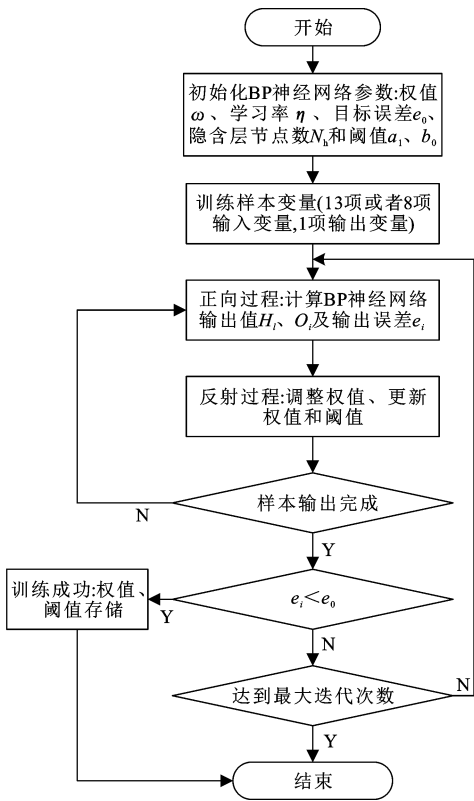


图 2 BP 神经网络混凝土抗压强度预测模型计算流程  
Fig. 2 Calculation process of BP neural network concrete compressive strength prediction model

步骤 1:初始化 BP 神经网络参数。设定最大迭代次数为 10 000,学习率  $\eta$  为 0.035,目标误差  $e_0$  为  $1.1e^{-2}$ 。设定输入层、隐含层、输出层各神经元之间突触权值分别为  $\omega_{j1}$ 、 $\omega_{j0}$ ,阈值  $a_1$ 、 $b_0$  为随机数。隐含层节点数  $N_h$  的取值区间通过式(1)计算。

$$N_h = \sqrt{N_i + N_o} + u_0 \tag{1}$$

式中: $N_i$ 、 $N_h$ 、 $N_o$  分别为输入层、隐含层和输出层的节点数; $u_0$  为常数, $u_0 \in [1, 10]$ , $u_0$  取值不同计算得出的隐含层节点数不同,利用不同隐含层节点数模型进行预测,根据预测值误差平均值与样本拟合系数  $R$  确定最佳隐含层节点数值。

步骤 2:输入训练样本。假设有  $m$  组混凝土拌和生产实时监控数据样本  $\{X^1, X^2, \dots, X^m\}$ ,其中第  $i$  组样本  $X^i$  有  $n$  项数据,即  $X^i = \{x_1^i, x_2^i, \dots, x_n^i\}$ ,将第  $i$  组样本中的数据  $X^i$  和对应抗压强度值  $p_i$  作为输入训练样本集  $\{[X^i, p_i]\} = 1$ 。顺序赋值的输入向量为  $[X^1, X^2, \dots, X^i]$ ,期望输出响应为  $[p_1, p_2, \dots, p_i]$ 。当训练样本不足时,循环输入。

步骤 3:正向过程。针对第  $i$  组输入样本,计算样本在隐含层的输出  $H_i$  和输出层的输出  $O_i$  分别为

$$H_l = f(\sum_{j=1}^n \omega_{jl} x_j^i - a_l)$$

(2)

$$O_i = \sum_{l=1}^{N_h} H_l \omega_0 - b_0$$

(3)

式中: $f(*)$ 为激活函数,常用 sigmoid 函数; $j$ 为该组输入样本的输入变量项数, $j=1,2,\cdots,n$ ; $l$ 为隐含层的层数, $l=1,2,\cdots,N_h$ 。

计算网络预测输出值  $O_i$  和期望值  $p_i$  之间的预测误差  $e_i$  为

$$e_i = p_i - O_i$$

(4)

步骤 4:反向过程。利用预测误差  $e_i$  调整各层神经元之间的权值,即

$$\omega_{jl} = \omega_{jl} + \eta H_l (1 - H_l) x_j^i \omega_o e_i$$

(5)

$$\omega_o = \omega_o + \eta H_l e_i$$

(6)

根据预测误差  $e_i$  更新网络节点阈值  $a_l$ 、 $b_o$ ,即

$$a_l = a_l + \eta H_l (1 - H_l) \omega_o e_i$$

(7)

$$b_o = b_o + e_i$$

(8)

步骤 5:判断迭代是否满足终止条件,若不满足,则返回步骤 3。

## 2 实例验证及分析

### 2.1 数据处理与验证流程

实例验证数据为某混凝土拌和站 C40 配合比的拌和生产实时监控数据和每盘对应的 28 d 抗压强度试验数据,数据样本集 200 组,如表 1 所示。样本数据集按 6:2:2 划分为 120 组训练集、40 组验证集及 40 组测试集。对样本数据集进行归一化处理,利用训练集和验证集数据对 8 项输入变量和 13

项输入变量 BP 神经网络混凝土抗压强度预测模型进行训练和验证,利用测试集对训练后的 BP 神经网络预测模型进行测试,并将预测结果反归一化后与实际监控数据进行比较,计算得出误差指标,根据误差指标数据进行 BP 神经网络混凝土抗压强度预测模型有效性验证。同时,通过 8 项输入变量和 13 项输入变量 BP 预测模型的预测误差对比分析,优选确定预测模型的输入变量。

### 2.2 BP 神经网络预测模型验证

#### 2.2.1 隐含层节点计算

8 项输入变量和 13 项输入变量 BP 神经网络预测模型的输入层数量分别设定为 8 和 13,输出层数量设定为 1,根据式(1)计算得到隐含层节点数区间分别为[4,13]和[5,14]。利用表 1 前 120 组训练集数据作为训练样本,对不同隐含层节点数的 BP 神经网络预测模型进行训练,计算训练集均方误差,确定最小均方误差对应的隐含层节点数为最佳隐含层节点数,得到 8 项输入变量和 13 项输入变量 BP 神经网络混凝土抗压强度预测模型的最佳隐含层节点数分别为 8 和 11。

#### 2.2.2 BP 神经网络混凝土抗压强度预测模型验证

对应 8 项输入变量和 13 项输入变量,分别建立 8-8-1 结构和 13-11-1 结构的 BP 神经网络混凝土抗压强度预测模型。将两种模型的预测结果与 7 d 抗压强度试验结果估算值进行对比,结果如表 2 所示。

采用均方误差、均方根误差、平均绝对误差和平均绝对百分比误差指标评价不同预测模型的预测效果,各模型误差比较结果如表 3 所示。可以看出:两

表 1 C40 配比混凝土拌和生产监控数据和抗压试验数据样本集

Table 1 C40 proportioned concrete production monitoring data and compression test data sample set

组号	1	2	3	4	...	199	200
抗压强度/MPa	48.45	50.22	48.42	50.65	...	49.87	50.35
水泥掺量/kg	587.00	584.16	586.25	584.25	...	639.44	636.48
水掺量/kg	222.50	221.52	224.77	222.00	...	219.50	234.50
碎石 1 掺量/kg	650.00	652.13	652.00	654.12	...	636.00	636.53
碎石 2 掺量/kg	1 090.25	1 094.00	1 090.14	1 092.37	...	1 064.63	1 062.00
碎石 3 掺量/kg	440.10	434.14	436.00	438.19	...	424.26	424.54
砂子掺量/kg	1 446.22	1 454.67	1 454.80	1 446.57	...	1 424.17	1 380.41
粉煤灰掺量/kg	252.40	251.82	254.40	249.67	...	272.84	274.45
减水剂掺量/kg	8.38	8.39	8.38	8.37	...	9.13	9.15
胶凝材料配比	839.40	835.98	840.65	833.92	...	912.28	910.93
粗细骨料配比	3 626.57	3 634.94	3 632.94	3 631.25	...	3 549.06	3 503.48
水胶比	0.27	0.26	0.27	0.27	...	0.24	0.26
砂率	0.40	0.40	0.40	0.40	...	0.40	0.39
水灰比	0.38	0.38	0.38	0.38	...	0.34	0.37

表 2 BP 神经网络混凝土抗压强度预测模型预测结果比较

Table 2 Comparison of concrete compressive strength prediction results of BP neural network prediction models							
组号	抗压强度试验值/MPa	7 d 试验结果估算法		13-11-1 结构 BP 模型		8-8-1 结构 BP 模型	
		抗压强度估算值/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	50.12	51.53	2.82	50.83	1.43	49.62	−0.99
2	48.20	47.43	−1.60	48.89	1.42	48.15	−0.10
3	48.34	49.50	2.41	49.76	2.95	48.04	−0.61
4	48.07	49.25	2.45	48.55	0.99	48.32	0.52
5	50.43	48.57	−3.69	50.58	0.31	49.59	−1.65
6	48.67	48.25	−0.87	48.51	−0.33	48.44	−0.49
7	49.09	47.68	−2.87	50.96	3.82	50.21	2.29
8	49.79	51.05	2.53	49.06	−1.47	49.17	−1.25
9	48.60	50.16	3.21	48.17	−0.89	48.22	−0.79
10	49.70	48.47	−2.47	50.12	0.86	49.65	−0.09
11	47.58	46.69	−1.86	48.82	2.63	48.22	1.36
12	48.60	47.05	−3.19	48.93	0.67	48.38	−0.45
...	...	...	...	...	...	...	...
37	59.92	51.82	3.81	50.25	0.67	50.04	0.24
38	48.75	49.66	1.87	49.54	1.63	49.10	0.73
39	49.87	51.82	3.91	50.32	0.90	49.78	−0.17
40	50.35	51.68	2.64	51.24	1.76	50.13	−0.45

表 3 不同预测模型的预测误差比较

Table 3 Comparison of prediction errors of different prediction models			
模型类别	7 d 试验结果估算法	13-11-1 BP 模型	8-8-1 BP 模型
均方误差	1.72	0.59	0.27
均方根误差/MPa	1.31	0.77	0.52
平均绝对误差/MPa	1.24	0.65	0.40
平均绝对百分比误差/%	2.52	1.33	0.82

种 BP 神经网络模型的预测误差均优于 7 d 试验结果估算法,其中,8 项输入变量的 8-8-1 结构 BP 预测模型的平均绝对百分比误差和均方根误差分别为 0.82%和 0.52 MPa,优于 13 项输入变量的 13-11-1 结构 BP 预测模型的 1.33%和 0.77 MPa。原因是配比数据由实际称重数据的分类计算得到,5 项配比数据和 8 项物料称重数据存在相关性,输入数据的波动容易造成误差叠加,导致预测精度降低。因此,舍弃 5 项配比数据,将拌和生产数据中 8 项物料称重数据作为输入变量,优选 8-8-1 结构的 BP 神经网络混凝土抗压强度预测模型进行预测。

2.3 预测结果分析

2.3.1 预测效果分析

将表 2 中的预测数据可视化得到图 3。可以看出,利用 7 d 抗压强度试验结果估算的抗压强度波动最大,8 项输入变量 BP 神经网络混凝土抗压强度预测模型的预测结果更贴合于实测值。




图 3 混凝土抗压强度预测结果与估算结果对比  
Fig.3 Comparison of concrete compressive strength prediction results and estimation results

2.3.2 预测误差对比分析

利用表 2 中的误差数据,绘制预测相对误差雷达图,如图 4 所示。可以看出:7 d 抗压试验数据估算误差大部分为正值,且均方根误差和平均绝对百分比误差都最大,说明 7 d 试验数据估算方法比较开放乐观,实际中容易造成质量误判断。相对于 8 项输入量的 BP 预测模型,13 项输入量的 BP 预测模型预测误差较大,而且波动较大。综上,优选后的 8 项输入变量 BP 神经网络预测模型在基于混凝土拌和站实时监测数据的混凝土抗压强度预测精度方面有明显的优势。

2.3.3 迭代过程对比分析

将 8 项输入变量和 13 项输入变量的 BP 神经网络迭代运算过程进行对比,结果如图 5 所示。为




图 4 不同预测模型相对误差对比

Fig. 4 Comparison of relative errors of different prediction models




图 5 BP 神经网络预测模型迭代运算过程

Fig. 5 Iterative operation process of BP neural network prediction models

便于查看模型迭代趋势,对训练的均方误差  $E_{MSE}$  取对数。可以看出,8 项输入变量 BP 神经网络模型运算收敛更快,迭代曲线在约 3 000 步时已经趋于平稳,相比于 13 项输入变量的 BP 神经网络具有更好的收敛性和更高的运算效率。


2.4 适用性验证

2.4.1 数据集建立与划分


为验证 8 项输入变量 BP 神经网络混凝土抗压强度预测模型的适用性,收集来自不同拌和站的 C20、C30 两种不同配合比的混凝土拌和生产监控数据与抗压试验数据各 200 组,建立 C20 配比数据集和 C30 配比数据集。同样将数据集分别按照 6 : 2 : 2 比例划分为训练集、验证集与测试集,对优选后的 8 项输入变量 BP 神经网络混凝土抗压强度预测模型进行适应性验证。

2.4.2 模型训练与测试

对优选的 8 项输入变量 8-8-1 结构 BP 神经网络预测模型进行训练与测试,选择最大迭代次数为 10 000,设定学习率为 0.035,目标误差为  $1.1 \times 10^{-2}$ 。



(a) C20 配比



(b) C30 配比

图 6 不同配比混凝土抗压强度预测曲线

Fig. 6 Prediction curve of compressive strength of concrete with different proportions

得到测试集预测结果如图 6 所示。可以看出,该模型能够较好地预测 C20 配比和 C30 配比混凝土抗压强度,预测曲线与实测值曲线变化趋势同步性较高,未出现明显的波动差异,表明该模型能够基于实时拌和生产监测数据对不同强度等级配比的混凝土进行抗压强度预测。

2.4.3 预测误差分析

C20 配比与 C30 配比预测误差结果如表 4 所示。两种配比数据的预测均方根误差与平均绝对误差均未超过 0.6 MPa,均方误差均小于 0.3,且平均绝对百分比误差均在 2% 之内,与 C40 配比数据预测误差范围一致,进一步验证了该 BP 预测模型对混凝土强度预测的适用性及准确性。

表 4 不同配比数据集预测误差对比

Table 4 Comparison of prediction errors of different ratio data sets

配比数据种类	C20 配比	C30 配比
均方误差	0.22	0.28
均方根误差/MPa	0.46	0.53
平均绝对误差/MPa	0.37	0.39
平均绝对百分比误差/%	1.52	1.12

3 结 语

(1)本文以混凝土拌和生产实时监测数据作为输入变量,提出了一种 BP 神经网络混凝土抗压强

度预测模型并进行了实例验证,解决了传统混凝土试验周期长、工程效率低、成本高的问题。

(2)预测结果表明,以 8 项混凝土生产称重数据作为输入变量的 BP 神经网络混凝土抗压强度预测模型预测均方根误差为 0.52 MPa,平均绝对百分比误差为 0.82%,预测精度高,运算收敛性好。利用不同拌和站的 C20 配比、C30 配比数据集进行模型适应性验证,结果显示,模型预测精度高,均方误差小于 0.5 MPa,平均绝对百分比误差小于 2%,模型适用性得到进一步验证。

(3)本文提出的模型可以进一步对不同训练数据集数量、不同输入变量组合的混凝土拌和站实时监测数据进行混凝土抗压性能预测效果验证,进一步增强模型的泛化能力与适用性。

## 参考文献:

## References:

- [1] 白国良,刘瀚卿,朱可凡,等. 陕北矿区不同矿源煤矸石混凝土抗压强度试验研究[J]. 土木工程学报, 2023,56(4):30-40.  
BAI Guoliang, LIU Hanqing, ZHU Kefan, et al. Experimental study on compressive strength of coal gangue concrete from different ore sources in Northern Shaanxi mining area[J]. China Civil Engineering Journal, 2023,56(4):30-40.
- [2] NASER A H, BADR A H, HENEDY S N, et al. Application of multivariate adaptive regression splines (MARS) approach in prediction of compressive strength of eco-friendly concrete[J]. Case Studies in Construction Materials, 2022,17:e01262.
- [3] 薛国斌,胡安龙,魏 勇,等. 基于代价敏感系数的混凝土抗压强度预测[J]. 西安理工大学学报, 2022, 38(4):588-593.  
XUE Guobin, HU Anlong, WEI Yong, et al. Compressive strength prediction of concrete based on the cost-sensitive coefficients[J]. Journal of Xi'an University of Technology, 2022,38(4):588-593.
- [4] 陈洪根,龙蔚莹,李 昕,等. 基于 BP 神经网络的粉煤灰混凝土抗压强度预测研究[J]. 建筑结构, 2021, 51(增 2):1041-1045.  
CHEN Honggen, LONG Weiyang, LI Xin, et al. Prediction of compressive strength of fly ash concrete based on BP neural network[J]. Building Structure, 2021,51(S2):1041-1045.
- [5] 林 军,杨 斌,陈雁萍. 基于 FLR 和 ANFIS 方法预测混凝土抗压强度研究[J]. 混凝土, 2022(5):11-15.  
LIN Jun, YANG Bin, CHEN Yanping. Comparison
- study of predicting concrete compressive strength by FLR and ANFIS method[J]. Concrete, 2022(5):11-15.
- [6] 吴贤国,刘鹏程,陈虹宇,等. 基于随机森林的高性能混凝土抗压强度预测[J]. 混凝土, 2022(1):17-20, 24.  
WU Xianguo, LIU Pengcheng, CHEN Hongyu, et al. Characteristic screening and prediction of high-performance concrete compressive strength based on random forest method[J]. Concrete, 2022(1):17-20, 24.
- [7] ZENG Z Y, ZHU Z Y, YAO W, et al. Accurate prediction of concrete compressive strength based on explainable features using deep learning[J]. Construction and Building Materials, 2022,329:127082.
- [8] ZHU L H, ZHAO C, DAI J. Prediction of compressive strength of recycled aggregate concrete based on gray correlation analysis[J]. Construction and Building Materials, 2021,273:121750.
- [9] 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.
- [10] WANG R L, DAI Y M, HAN C C, et al. Application of DPO-BP in strength prediction of concrete[C]// ITOEC. Proceedings of 2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference. Chongqing: IEEE, 2017:1003-1006.
- [11] 焦楚杰,谭思琪,崔力仕,等. 基于神经网络的植生型多孔混凝土抗压强度预测模型[J]. 混凝土, 2022(1): 7-10,16.  
JIAO Chuji, TAN Siqi, CUI Lishi, et al. Prediction model of compressive strength of plant porous concrete based on neural network[J]. Concrete, 2022(1): 7-10,16.
- [12] TU J S, LIU Y Z, ZHOU M, et al. Prediction and analysis of compressive strength of recycled aggregate thermal insulation concrete based on GA-BP optimization network[J]. Journal of Engineering, Design and Technology, 2021,19(2):412-422.
- [13] FENG D C, LIU Z T, WANG X D, et al. Machine learning-based compressive strength prediction for concrete: an adaptive boosting approach[J]. Construction and Building Materials, 2020,230:117000.
- [14] AL-JAMIMI H A, AL-KUTTI W A, ALWAHAISHI

S, et al. Prediction of compressive strength in plain and blended cement concretes using a hybrid artificial intelligence model[J]. Case Studies in Construction Materials, 2022, 17: e01238.

[15] MA S X, SHI X X, YU C L, et al. Research on improved BP neural network gangue powder concrete compressive strength prediction model[C]//ITAIC. Proceedings of 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference, Chongqing: IEEE, 2020: 419-423.

[16] 许开成, 毕丽苹, 陈梦成. 基于 SPSS 回归分析的锂渣混凝土抗压强度预测模型[J]. 建筑科学与工程学报, 2017, 34(1): 15-24.

XU Kaicheng, BI Liping, CHEN Mengcheng. Prediction model of compressive strength of lithium slag concrete based on SPSS regression analysis[J]. Journal of Architecture and Civil Engineering, 2017, 34(1): 15-24.

[17] JOVIC S, BABIC L, MISKOVIC A, et al. Ranking of the most influential parameters for compressive strength of no-slump concrete prediction by neuro-fuzzy logic[J]. Structural Concrete, 2021, 22(2): 1-6.

[18] CUI X N, WANG Q C, ZHANG R L, et al. Machine learning prediction of concrete compressive strength with data enhancement[J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(6): 7219-7228.