

文章编号:1007-9629(2024)03-0189-08

基于 PSO-BPNN 模型的氯氧镁水泥混凝土 耐水性预测

王鹏辉¹, 乔宏霞^{2,*}, 冯琼², 薛翠真², 张云升^{2,3}

(1. 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;

2. 兰州理工大学 甘肃省土木工程防灾减灾重点实验室, 甘肃 兰州 730050;

3. 东南大学 材料科学与工程学院, 江苏 南京 211189)

摘要:为快速准确地获得具有优异耐水性氯氧镁水泥混凝土(MOCC)的配合比,设计了拓扑结构为 4-10-2 的粒子群优化(PSO)算法-反向传播(BP)神经网络(PSO-BPNN)模型.该模型的输入层参数为 $n(\text{MgO})/n(\text{MgCl}_2)$ 、粉煤灰掺量、磷酸掺量和磷肥掺量,输出层参数为 MOCC 的抗压强度和软化系数;模型数据集为 144 组,其中训练集数据为 100 组,验证集数据为 22 组,测试集数据为 22 组.结果表明:PSO-BPNN 模型在 MOCC 抗压强度预测中的评价参数——决定系数 $R^2=0.99$ 、平均绝对误差 $S_{\text{MAE}}=0.52$ 、平均绝对误差百分比 $S_{\text{MAPE}}=1.11$ 、均方根误差 $S_{\text{RMSE}}=0.73$;其在软化系数预测中的评价参数—— $R^2=0.99$ 、 $S_{\text{MAE}}=0.44$ 、 $S_{\text{MAPE}}=1.29$ 、 $S_{\text{RMSE}}=0.62$;与 BP 神经网络(BPNN)模型相比,PSO-BPNN 模型具有更强的双参数预测能力,可用于 MOCC 配合比的正向设计和反向指导.

关键词:氯氧镁水泥混凝土;耐水性;抗压强度;软化系数;PSO-BPNN

中图分类号:TU528.01

文献标志码:A

doi:10.3969/j.issn.1007-9629.2024.03.001

Prediction of Water Resistance of Magnesium Oxychloride Cement Concrete Based on PSO-BPNN Model

WANG Penghui¹, QIAO Hongxia^{2,*}, FENG Qiong², XUE Cuizhen², ZHANG Yunsheng^{2,3}

(1. Guangdong Provincial Key Laboratory of Durability of Binhai Civil Engineering, Shenzhen University, Shenzhen

518060, China; 2. Key Laboratory of Disaster Prevention and Mitigation in Civil Engineering of Gansu Province,

Lanzhou University of Technology, Lanzhou 730050, China; 3. School of Materials Science and Engineering,

Southeast University, Nanjing 211189, China)

Abstract: In order to quickly and accurately obtain magnesium oxychloride cement concrete (MOCC) proportions with excellent water resistance, a particle swarm optimization back propagation neural network (PSO-BPNN) model with a topology of 4-10-2 was designed. The input layer parameters of the above model were $n(\text{MgO})/n(\text{MgCl}_2)$, fly ash content, phosphoric acid content, and phosphate fertilizer content. The output layer parameters were MOCC compressive strength and softening coefficient. The model establishment data set contained 144 groups, including 100 groups of training set data, 22 groups of validation set data, and 22 groups of test set data. The results show that the mean value of each evaluation parameter in the prediction of compressive strength using the PSO-BPNN model are coefficient of determination $R^2=0.99$, mean absolute error $S_{\text{MAE}}=0.52$, mean absolute percentage error $S_{\text{MAPE}}=1.11$, and root mean square error $S_{\text{RMSE}}=0.73$. The mean value of each evaluation parameters in the prediction

收稿日期:2023-03-22; 修订日期:2023-07-21

基金项目:国家自然科学基金资助项目(52178216, 52108219, U21A20150, 52008196);甘肃省科技计划项目(23JRRA799)

第一作者:王鹏辉(1991—),男,河南洛阳人,深圳大学副研究员,博士.E-mail:356984639@qq.com

通讯作者:乔宏霞(1977—),女,山西应县人,兰州理工大学教授,博士生导师,博士.E-mail:qiaohongxia@lut.edu.cn

of softening coefficient are $R^2=0.99$, $S_{MAE}=0.44$, $S_{MAPE}=1.29$, and $S_{RMSE}=0.62$. This indicates that compared to the BP neural network (BPNN) model, the PSO-BPNN model has a strong ability to predict dual parameters and can be used for both forward design and reverse guidance of MOCC mix proportions.

Key words: magnesium oxychloride cement concrete; water resistance; compressive strength; softening coefficient; PSO-BPNN

耐水性不足是影响氯氧镁水泥混凝土(MOCC)长期服役性能的关键问题. MOCC的水化产物 $5\text{Mg}(\text{OH})_2 \cdot \text{MgCl}_2 \cdot 8\text{H}_2\text{O}$ (简称相5)和 $3\text{Mg}(\text{OH})_2 \cdot \text{MgCl}_2 \cdot 8\text{H}_2\text{O}$ (简称相3)在潮湿环境下易水解为 $\text{Mg}(\text{OH})_2$ 和 MgCl_2 ,使水泥石孔隙率增加,从而导致MOCC强度下降^[1-2].

耐水剂种类和掺量^[3]与MOCC抗压强度和软化系数之间存在复杂的非线性关系,目前尚无能够准确反映和阐明这种非线性关系的通用方程,另外确定合适的耐水剂掺量也须进行庞大的试验^[4-5]. 因此,需要建立简明的通用方程来充分反映耐水剂掺量及种类与MOCC抗压强度、软化系数之间的非线性关系. 粒子群优化(PSO)算法-反向传播(BP)神经网络(PSO-BPNN)模型^[6-9]以自组织、自适应和全局搜索特点,使其具备可解决复杂非线性映射问题的能力. 由于PSO-BPNN模型在混凝土和复合材料抗压强度预测^[10-12]等方面均已得到广泛应用,因此采用其对MOCC耐水性进行预测成为可能.

鉴于此,本文设计了24组配合比,通过长期耐水性试验对MOCC的耐水效果进行分析,并以 $n(\text{MgO})/n(\text{MgCl}_2)$ 、粉煤灰掺量、磷酸掺量和磷肥掺量为输入参数,以MOCC抗压强度和软化系数为输出参数,设计了拓扑结构为4-10-2的PSO-BPNN模型,以期对MOCC的耐水性预测提供指导,并为其配合比设计提供科学依据.

1 试验

1.1 原材料

MOCC由 MgO 、 MgCl_2 、I级粉煤灰(FA)、粗集料、细集料、减水剂和耐水剂组成. 其中粗集料为粒径5~25 mm连续级配的石子(AE),细集料为级配良好的中砂(SD),二者均符合JGJ 52—2006《普通混凝土用砂、石质量及检验方法》要求;减水剂为KD萘系高效减水剂(WRA),减水率(质量分数,文中涉及的减水率、含量等除特别注解外均为质量分数)为15%~25%;耐水剂为磷酸(PA)和磷肥(PF),PA中的 H_3PO_4 含量不小于85.0%,色度不大于25,PF的主要成分为 $\text{Ca}(\text{H}_2\text{PO}_4)_2$,二者均符合

GB 8076—2008《混凝土外加剂》要求.

1.2 试验方案

MOCC的配合比如表1所示,其中 MgCl_2 溶液(MS)中 MgCl_2 的质量分数为23%. 根据GB/T 50082—2009《普通混凝土长期性能和耐久性能试验方法标准》,将MOCC混合料制备好后倒入模具,24 h后拆模,试件尺寸为150 mm×150 mm×150 mm,并置于养护室($(20 \pm 2)^\circ\text{C}$ 、相对湿度 $(37 \pm 2)\%$)中干燥养护至28 d. 将试件分为2组,其中1组进行抗压强度测试;另1组进行耐水性试验,水面超过试件表面3 cm. 待MOCC试件浸泡至28.360 d时,分别进行抗压强度测试,并按式(1)计算其软化系数 K .

$$K = \frac{f_w}{f} \quad (1)$$

式中: f_w 为MOCC在浸水环境下的抗压强度,MPa; f 为MOCC在干燥环境下的抗压强度,MPa.

1.3 模型参数确定

本文模型建立的数据集由144组MOCC抗压强度和软化系数组成,其中100组数据(70%)用于训练神经网络模型,22组数据(15%)用于验证数据,22组数据(15%)用于测试数据. 由于适当增加神经元节点数量,可使单个隐含层的网络实现非线性映射^[13],因此本文选用单层神经网络,其中隐含层的节点数 m 采用式(2)进行计算.

$$m = a \log_2 n \quad (2)$$

式中: a 为修正系数; n 为输入层的节点数.

本文 $n=4$, a 取为4、5、6、7、8、9和10,通过式(2)计算得到 $m=8、10、12、14、16、18、20$. 考虑到模型的预测精度、误差波动范围及迭代次数等因素,将 m 取为10,具体计算过程可参考文献[14]. 最终确定训练模型算法为PSO算法,拓扑结构为4-10-2. BPNN的模型结构如图1所示. 其中, x_i ($i=1、2、3、4$)为输入变量; $i、j$ 和 k 分别为输入层、隐含层和输出层的节点; w_{ij} 和 w_{jk} 为层间的连接权值;OUT1和OUT2分别为MOCC的抗压强度和软化系数预测值;EXP1和EXP2分别为MOCC的抗压强度和软化系数实际值; y_1 和 y_2 分别为MOCC的抗压强度和软化系数预测值与实际值之差.

表1 MOCC的配合比
Table 1 Mix proportions of MOCCs

Unit: kg/m ³									
Group No.	Specimen No.	MgO	MS	AE	SD	FA	PA	PF	WRA
A	A-0	389.00	301.00	1 162.00	625.00	0	4.58	0	16.02
	A-1	389.00	301.00	1 162.00	625.00	34.32	4.58	0	16.02
	A-2	389.00	301.00	1 162.00	625.00	68.64	4.58	0	16.02
	A-3	389.00	301.00	1 162.00	625.00	102.96	4.58	0	16.02
B	B-0	389.00	301.00	1 162.00	625.00	0	0	9.15	16.02
	B-1	389.00	301.00	1 162.00	625.00	34.32	0	9.15	16.02
	B-2	389.00	301.00	1 162.00	625.00	68.64	0	9.15	16.02
	B-3	389.00	301.00	1 162.00	625.00	102.96	0	9.15	16.02
C	C-0	389.00	271.00	1 162.00	625.00	0	4.58	0	16.02
	C-1	389.00	271.00	1 162.00	625.00	34.32	4.58	0	16.02
	C-2	389.00	271.00	1 162.00	625.00	68.64	4.58	0	16.02
	C-3	389.00	271.00	1 162.00	625.00	102.96	4.58	0	16.02
D	D-0	389.00	271.00	1 162.00	625.00	0	0	9.15	16.02
	D-1	389.00	271.00	1 162.00	625.00	34.32	0	9.15	16.02
	D-2	389.00	271.00	1 162.00	625.00	68.64	0	9.15	16.02
	D-3	389.00	271.00	1 162.00	625.00	102.96	0	9.15	16.02
E	E-0	389.00	246.00	1 162.00	625.00	0	4.58	0	16.02
	E-1	389.00	246.00	1 162.00	625.00	34.32	4.58	0	16.02
	E-2	389.00	246.00	1 162.00	625.00	68.64	4.58	0	16.02
	E-3	389.00	246.00	1 162.00	625.00	102.96	4.58	0	16.02
F	F-0	389.00	246.00	1 162.00	625.00	0	0	9.15	16.02
	F-1	389.00	246.00	1 162.00	625.00	34.32	0	9.15	16.02
	F-2	389.00	246.00	1 162.00	625.00	68.64	0	9.15	16.02
	F-3	389.00	246.00	1 162.00	625.00	102.96	0	9.15	16.02




图1 BPNN的模型结构
Fig. 1 Structure diagram of BPNN model

2 基础理论

2.1 PSO 算法

PSO算法的核心思想是通过模拟鸟群觅食时个体之间的信息共享来获得最优解的.先赋予所有粒

子随机初始位置和速度,再根据粒子已知的最优位置逼近问题空间中已知的最优全局位置,通过不断迭代来获得全局最优解.在求解过程中,每个粒子的速度和位置均由自身的最佳过去位置和整个群或近邻的最佳过去位置决定,其表达式见式(3)、(4)^[11-12].

$$\mathbf{v}_{ij}(t+1) = \omega \mathbf{v}_{ij}(t) + r_1 c_1 [\mathbf{p}_{ij}(t) - \mathbf{x}_{ij}(t)] + r_2 c_2 [\mathbf{g}_{ij}(t) - \mathbf{x}_{ij}(t)] \quad (3)$$

$$\mathbf{x}_{ij}(t+1) = \mathbf{x}_{ij}(t) + \mathbf{v}_{ij}(t+1) \quad (4)$$

式中: $\mathbf{v}_{ij}(t)$ 和 $\mathbf{v}_{ij}(t+1)$ 分别为粒子在 t 和 $t+1$ 时刻的速度向量; $\mathbf{x}_{ij}(t)$ 和 $\mathbf{x}_{ij}(t+1)$ 分别为粒子在 t 和 $t+1$ 时刻的位置向量; $\mathbf{p}_{ij}(t)$ 为 t 时刻个体的最优位置; $\mathbf{g}_{ij}(t)$ 为 t 时刻群体的最优位置; ω 为最佳惯性权重, 介于 $[0, 1]$ 之间, 在一般应用中采用自适应取值方法; c_1 和 c_2 为学习因子; r_1 和 r_2 为随机函数, 介于 $[0, 1]$ 之间, 用于增加搜索随机性。

2.2 评价参数

为评价 PSO-BPNN 模型对 MOCC 抗压强度和软化系数的预测效果, 采用均方根误差 S_{RMSE} 、平均绝对误差 S_{MAE} 、平均绝对误差百分比 S_{MAPE} 、相关系数 R 和决定系数 R^2 等参数^[13-14] 对各模型的预测精度进行评价。

2.3 计算步骤

MOCC 抗压强度和软化系数预测模型的建立主要包括以下步骤:

(1) 确定数据集 将影响 MOCC 耐水性的 4 个因素—— $n(\text{MgO}/n(\text{MgCl}_2))$ 、粉煤灰掺量 $w(\text{FA})$ 、磷酸掺量 $w(\text{PA})$ 和磷肥掺量 $w(\text{PF})$ 作为输入参数, 以 MOCC 抗压强度和软化系数为输出参数。

(2) 训练模型 基于前期建立的数据集, 对 BPNN、PSO-BPNN 模型进行训练, 并采用相关系数

R 对模型的预测能力进行初步分析。

(3) 模型评估 以统计参数 S_{RMSE} 、 S_{MAE} 、 S_{MAPE} 和 R^2 对 BPNN 和 PSO-BPNN 模型的预测能力进行评估。

(4) 模型验证 选用 22 组实测数据对已建立的 PSO-BPNN 模型进行验证, 并对模型的精度和稳定性进行预测。

3 结果与讨论

3.1 相关性分析

MOCC 的抗压强度 (干燥环境) 和软化系数如图 2 所示。由图 2 可见: 经过 360 d 的干燥养护, MOCC 的抗压强度与养护 28 d 时相比有所提升; 而经过浸水试验后, MOCC 的软化系数有明显下降。强度提升的原因是随着水泥水化的不断进行, 水化产物中提供主要强度的相 5 和相 3 含量不断增加。软化系数降低的主要原因是水化产物相 5 和相 3 在潮湿环境下水解成 $\text{Mg}(\text{OH})_2$ 和 MgCl_2 。由图 2 还可见, 不同配合比下 MOCC 的软化系数呈现显著的非线性关系。由此可见, 常用方程难以同时预测 MOCC 的抗压强度和软化系数。




图2 MOCC的抗压强度和软化系数

Fig. 2 Compressive strength and softening coefficient of MOCC

为研究 MOCC 的耐水性, 以 $n(\text{MgO})/n(\text{MgCl}_2)$ 、粉煤灰掺量、磷酸掺量和磷肥掺量作为影响因素, 以 MOCC 的抗压强度和软化系数作为评价指标, 采用相关系数矩阵, 对不同养护龄期下的相关性进行分析, 结果如图 3 所示, 其中 n_t 表示 $n(\text{MgO})/n(\text{MgCl}_2)$; f_w 为 MOCC 在潮湿环境下的抗压强度。

由图 3 可见: (1) 当养护龄期为 28 d 时, $n(\text{MgO})/$

$n(\text{MgCl}_2)$ 与 MOCC 抗压强度 (干燥环境及潮湿环境) 和软化系数的相关系数分别为 -0.90 、 -0.94 和 -0.74 ; 当养护龄期为 360 d 时, $n(\text{MgO})/n(\text{MgCl}_2)$ 与 MOCC 抗压强度 (干燥环境及潮湿环境) 和软化系数的相关系数分别为 -0.74 、 -0.82 和 -0.28 , 这表明不论养护龄期是 28 d 还是 360 d, $n(\text{MgO})/n(\text{MgCl}_2)$ 与 MOCC 抗压强度 (干燥环境及潮湿环

境)和软化系数均呈负相关。(2)当养护龄期为 28 d 时,FA 掺量与 MOCC 抗压强度(干燥环境及潮湿环境)和软化系数的相关系数分别为 -0.34 、 -0.09 和 0.51 ;当养护龄期为 360 d 时,FA 掺量与 MOCC 抗压强度(干燥环境及潮湿环境)和软化系数的相关系数分别为 -0.31 、 0.26 、 0.76 。这表明 FA 掺量与干燥环境下 MOCC 的抗压强度呈负相关,与潮湿环境下 MOCC 的抗压强度和软化系数呈正相关。这是由于 FA 的掺入减少了 MOCC 主要强度来源相 5 的含量,随着 FA 掺量的增加,MOCC 抗压强度不断降低^[15];FA 中的活性 Si 可能与氯氧镁水泥中过剩的 Mg^{2+} 发生反应,生成 $MgSiO_3$ 凝胶,在一定程度上降低了可溶性 Mg^{2+} 的浓度,减小了孔隙率,从而提高了 MOCC 的耐水性^[15]。(3)当养护龄期为 28 d 时,PA 掺

量与 MOCC 抗压强度(干燥环境及潮湿环境)和软化系数的相关系数分别为 0.22 、 0.22 和 0.09 ;当养护龄期为 360 d 时,PA 掺量与 MOCC 抗压强度及软化系数的相关系数分别为 -0.54 、 -0.29 和 0.26 。这表明 PA 掺量与 MOCC 的长期抗压强度呈负相关,与其耐水性呈正相关。(4)当养护龄期为 28 d 时,PF 掺量与 MOCC 抗压强度(干燥环境及潮湿环境)和软化系数的相关系数分别为 -0.22 、 -0.22 和 -0.09 ;当养护龄期为 360 d 时,PF 掺量与 MOCC 抗压强度(干燥环境及潮湿环境)和软化系数的相关系数分别为 0.54 、 0.29 和 -0.26 。这表明养护龄期为 28 d 时,PF 掺量与 MOCC 抗压强度和软化系数呈负相关;当养护龄期为 360 d 时,PF 掺量与 MOCC 抗压强度呈正相关,与其软化系数呈负相关。




图3 相关系数矩阵

Fig. 3 Correlation coefficient matrix

3.2 模型建立

BPNN 和 PSO-BPNN 模型的网络训练、验证、测试及输出值/实际值拟合线如图 4 所示。由图 4 可见:2 种模型的输出值与实际值的相关性可用线性关系表达;BPNN 和 PSO-BPNN 模型的训练过程相关系数 R_{BPNN} 和 $R_{PSO-BPNN}$ 分别为 0.977 和 0.987,验证过程 R_{BPNN} 和 $R_{PSO-BPNN}$ 分别为 0.935 和 0.976,测试过程 R_{BPNN} 和 $R_{PSO-BPNN}$ 分别为 0.873 和 0.983;整体 R_{BPNN} 和 $R_{PSO-BPNN}$ 分别为 0.952 和 0.984。这表明,采用 PSO 算法优化后的 BPNN 模型预测能力要优于未经优化的 BPNN 模型,且其整体相关系数在 0.980 以上。

为进一步分析上述模型综合预测能力的稳定性,用 R^2 、 S_{MAE} 、 S_{MAPE} 和 S_{RMSE} 对其进行评价,上述评价参数的 10 次预测结果如图 5 所示。由图 5 可见:

PSO-BPNN 模型训练集的 R^2 大于 BPNN 模型,其 S_{MAE} 、 S_{MAPE} 和 S_{RMSE} 均小于 BPNN 模型;PSO-BPNN 模型测试集的 R^2 大于 BPNN 模型,其 S_{MAE} 、 S_{MAPE} 和 S_{RMSE} 均小于 BPNN 模型。由此可初步表明,与 BPNN 模型相比,PSO-BPNN 模型为较优预测模型,其在预测 MOCC 抗压强度和软化系数上具有更强优势。

3.3 预测模型验证

为了验证 BPNN 和 PSO-BPNN 模型的预测能力,分别计算各评价参数的均值,结果如图 6 所示。由图 6 可见,与 BPNN 模型相比,PSO-BPNN 模型的 R^2 较大,PSO-BPNN 模型的 S_{MAE} 、 S_{MAPE} 和 S_{RMSE} 较小。这表明 PSO-BPNN 模型的预测能力较强,且其稳定性较高,可用来预测 MOCC 的长期抗压强度和软化系数。该结论与 Zhang 等^[11]、Van 等^[17] 和 Han 等^[18] 的研

究结果一致.

以上验证分析进一步表明,经 PSO 优化的 BPNN 模型预测精度优于未优化的 BPNN 模型.这是因为 PSO 在进化算法方面具有一些优势,例如

PSO 算法没有复杂的算子^[16],通过每个粒子在空间的随机搜索,就能够实现更强的全局寻优能力^[17-18],将 BPNN 和 PSO 优化算法结合可以提高 BPNN 模型对数据的拟合程度,具有更高的预测精度.




图4 BPNN 和 PSO-BPNN 模型建立

Fig. 4 Establishment of BPNN and PSO-BPNN model




图5 BPNN 和 PSO-BPNN 模型的评价参数

Fig. 5 Evaluation parameters of BPNN and PSO-BPNN model




图6 BPNN和PSO-BPNN模型验证的评价参数

Fig. 6 Evaluation parameters of BPNN and PSO-BPNN model validation

4 结论

(1)通过相关系数矩阵分析了耐水性原材料对MOCC抗压强度和软化系数的影响,研究发现: $n(\text{MgO}/n(\text{MgCl}_2))$ 与MOCC抗压强度(干燥环境和潮湿环境)和软化系数呈负相关;粉煤灰掺量与MOCC抗压强度(干燥环境)呈负相关,与其抗压强度(潮湿环境)和软化系数呈正相关;磷酸掺量与MOCC抗压强度(干燥环境和潮湿环境)呈负相关,与其软化系数呈正相关;磷肥掺量与MOCC抗压强度(干燥环境和潮湿环境)呈正相关,与其软化系数呈负相关。

(2)PSO-BPNN模型与BPNN模型在MOCC抗压强度和软化系数预测中各评价参数(决定系数 R^2 、平均绝对误差 S_{MAE} 、平均绝对误差百分比 S_{MAPE} 、均方根误差 S_{RMSE})的对比结果表明,PSO-BPNN模型的预测能力比BPNN模型更强。

(3)PSO算法不会因为个别样本是异常值就影响模型对整体问题的求解,该算法使模型更具有鲁棒性,其在混凝土这种多相异性材料的服役性能预测上具有天然的相适性,可推广至混凝土在高低温、冻融循环和碳化等不同环境下的性能预测。

参考文献:

- [1] 王鹏辉,乔宏霞,冯琼,等.氯氧镁水泥混凝土中涂层钢筋的耐久性退化研究[J].建筑材料学报,2020,23(3):563-571.
WANG Penghui, QIAO Hongxia, FENG Qiong, et al. Study on durability degradation of coated steel in magnesium oxychloride concrete[J]. Journal of Building Materials, 2020, 23(3): 563-571. (in Chinese)
- [2] 顾康,陈兵.柠檬酸和柠檬酸铵对氯氧镁水泥水稳定性的改善机理[J].建筑材料学报,2022,25(5):441-446.
GU Kang, CHEN Bing. Mechanism of citric acid and ammonium

- citrate tribasic on improving water stability of magnesium oxychloride cement[J]. Journal of Building Materials, 2022, 25(5):441-446. (in Chinese)
- [3] DENG D H. The mechanism for soluble phosphates to improve the water resistance of magnesium oxychloride cement [J]. Cement and Concrete Research, 2003, 33(9):1311-1317.
- [4] 陈啸洋,毕万利,张婷婷,等.柠檬酸对氯氧镁水泥的改性[J].硅酸盐学报,2019,47(7):884-890.
CHEN Xiaoyang, BI Wanli, ZHANG Tingting, et al. Modification of magnesium oxychloride cement by citric acid [J]. Journal of the Chinese Ceramic Society, 2019, 47(7):884-890. (in Chinese)
- [5] YE Q Q, HAN Y F, ZHANG S F, et al. Bioinspired and biomineralized magnesium oxychloride cement with enhanced compressive strength and water resistance [J]. Journal of Hazardous Materials, 2020, 383:121099.
- [6] 王志祥,李建阁.基于DNN改性沥青中SBS含量的预测模型[J].建筑材料学报,2021,24(3):630-636.
WANG Zhixiang, LI Jiange. Determination model of SBS content in modified asphalt based on DNN [J]. Journal of Building Materials, 2021, 24(3):630-636. (in Chinese)
- [7] 张涛,王才进,刘松玉,等.基于ANN的岩土体热阻系数预测模型研究[J].建筑材料学报,2020,23(2):381-391.
ZHANG Tao, WANG Caijin, LIU Songyu, et al. Prediction model of thermal resistivity of geomaterial based on artificial neural network[J]. Journal of Building Materials, 2020, 23(2): 381-391. (in Chinese)
- [8] 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. (in Chinese)
- [9] MEI X C, LI C Q, SHENG Q, et al. Development of a hybrid artificial intelligence model to predict the uniaxial compressive strength of a new aseismic layer made of rubber-sand concrete[J]. Mechanics of Advanced Materials and Structures, 2023, 30(11): 2185-2202.

- [10] LI Z X, ZHANG X J, SHI Y C, et al. Predication of the residual axial load capacity of CFRP-strengthened RC column subjected to blast loading using artificial neural network[J]. *Engineering Structures*, 2021, 242:112519.
- [11] ZHANG J F, HUANG Y M, WANG Y H, et al. Multi-objective optimization of concrete mixture proportions using machine learning and metaheuristic algorithms [J]. *Construction and Building Materials*, 2020, 253:119208.
- [12] LY H B, NGUYEN M H, PHAM B T. Metaheuristic optimization of Levenberg-Marquardt-based artificial neural network using particle swarm optimization for prediction of foamed concrete compressive strength[J]. *Neural Computing and Applications*, 2021, 33(24):17331-17351.
- [13] HUANG L H, CHEN J, TAN X Y. BP-ANN based bond strength prediction for FRP reinforced concrete at high temperature[J]. *Engineering Structures*, 2022, 257:114026.
- [14] NIAN T F, LI J G, 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, 351:128969.
- [15] 赵华,王永维,关博文,等. 粉煤灰对氯氧镁水泥早期性能的影响[J]. *材料导报*, 2015, 29(18):117-121, 135.
ZHAO Hua, WANG Yongwei, GUAN Bowen, et al. Effect of fly ash on early properties of magnesium oxychloride cement[J]. *Materials Reports*, 2015, 29(18):117-121, 135. (in Chinese)
- [16] SHAMSABADI E A, ROSHAN N, HADIGHEH S A, et al. Machine learning-based compressive strength modelling of concrete incorporating waste marble powder[J]. *Construction and Building Materials*, 2022, 324:126592.
- [17] VAN Q T, VIET Q D, LANH S H. Evaluating compressive strength of concrete made with recycled concrete aggregates using machine learning approach [J]. *Construction and Building Materials*, 2022, 323:126578.
- [18] HAN F, YAO H F, LING Q H. An improved evolutionary extreme learning machine based on particle swarm optimization [J]. *Neurocomputing*, 2013, 116:87-93.