

基于人工神经网络模型预测混凝土抗压强度*

An ANN Model for Predicting the Compressive Strength of Concrete

李风增^{1,2}

(1. 郑州市公路事业发展中心, 河南 郑州 450015;
2. 河南省交通科学技术研究院有限公司, 河南 郑州 450015)

摘要: 28 d 抗压强度是混凝土应用过程中重要的强度指标。本文采用人工神经网络模型 (ANN) 对加入了高炉矿渣和粉煤灰的混凝土 28 d 抗压强度进行了预测, 研究了 ANN 隐含层数、传递函数类型和优化算法对抗压强度预测结果的影响, 发现采用单一隐含层的 7-23-1 网络结构、隐含层和输出层均采用 purelin 传递函数、trainlm 算法进行计算, 建立的 ANN 结构最佳, 仅需 0.29 s、经过 3 个历元, 预测值的 MSE 就能降到 0.004 左右, 训练、验证和测试阶段 ANN 的预测结果与试验结果回归曲线斜率均大于 97%, 两者十分吻合。

关键词: 混凝土; 抗压强度; 人工神经网络; 预测

中图分类号: TV431 文献标志码: A 文章编号: 1005-8249 (2023) 03-0020-08

DOI: 10.19860/j.cnki.issn1005-8249.2023.03.020

LI Fengzeng^{1,2}

(1. Zhengzhou Highway Development Centre, Zhengzhou 450015, China;
2. Henan Transportation Research Institute Co., Ltd., Zhengzhou 450015, China)

Abstract: The 28 d compressive strength is an important index in concrete application. In this study, an artificial neural network model (ANN) was used to predict the compressive strength of concrete added with blast furnace slag and fly ash. The effects of number of hidden layer, transfer function types and optimization algorithms on ANN output were researched. The results showed that the 7-23-1 network structure with one hidden layer, purelin transfer function in the hidden and output layer, and trainlm algorithm established the optimal network. The established ANN only takes 0.29 seconds to reduce the MSE of prediction values to about 0.004 with 3 epoches. The slopes of the regression curves between the ANN outputs and the experimental results in the training, verification, and testing stages were greater than 97%, which indicated the consistence between prediction values and experimental ones.

Keywords: concrete; compressive strength; ANN; prediction

0 引言

混凝土是建筑行业应用最广的一种复合材料^[1-3]。抗压强度是混凝土应用过程中最重要的力学性能指标, 其影响因素众多, 混凝土中各组分含量, 如水、水泥、细骨料、粗骨料、添加剂、环境温度和湿度, 以及龄期均会对混凝土抗压强

* 基金项目: 河北省教育厅科研发展基金项目 (2020J0148)。

作者简介: 李风增 (1981—), 男, 硕士, 高级工程师, 国家注册一级建造师, 国家注册城市规划师。主要从事道路桥梁工程研究。

收稿日期: 2021-08-21

度产生影响。

丘丽妹^[4]采用单因素试验方法,研究了粉煤灰、再生骨料及石粉含量对混凝土抗压强度的影响;徐少成^[5]研究了砂率、水灰比、养护条件等对混凝土抗压强度的影响,发现砂率为 25%时,混凝土抗压强度最大;王军^[6]研究了钢纤维的加入对混凝土抗压强度、劈裂抗拉强度等力学性能的影响,发现钢纤维加入量为 0.6%和 1%时,混凝土抗压强度分别提升了 6.2%和 11.6%;赵杨^[3]研究了聚合物增效剂对混凝土抗压强度的影响,发现增效剂添加量为 0.6%时,混凝土抗压强度提高了 43.3%。

混凝土抗压强度按照 GB/T 50081-2002《普通混凝土力学性能试验方法标准》进行测试,过程耗时且繁琐,严重制约了混凝土性能的改进和应用。为了提高混凝土力学性能的分析效率,研究者提出了众多模型对其进行预测。葛培^[7]对混凝土 Bolomey 抗压强度计算模型进行了修正,建立了混杂再生骨料混凝土抗压强度计算模型,发现模型计算误差在 5%以内;徐存东^[8]构建了预测混凝土相对动弹性模量、剩余抗压强度等力学性能的灰色 GM 模型,获得的预测模型均能通过精度检验;高毅轩^[9]基于 Mori-Tanaka 均匀化理论对玄武岩纤维混凝土的弹性模量和抗压强度进行了分析,预测所得的弹性模量和抗压强度与试验结果吻合较好,误差小于 6.3%;凌建军^[10]采用三阶非线性函数预测了玄武岩机制砂混凝土的抗压强度,发现建立的预测模型精度较高。由于影响混凝土抗压强度的因素众多,很难建立一个机理模型对抗压强度进行准确预测^[11-12]。

随着人工智能技术的进步,研究者将不同的

机器学习算法用于预测混凝土的性能^[13-14]。Latif^[15]采用回归树(BDTR)和支持向量机(SVM)模型预测了混凝土抗压强度;Salami^[16]将最小二乘支持向量机(LSSVM)和耦合模拟退火(CSA)以及遗传算法(GA)相结合,研究了高炉矿渣和粉煤灰的加入对混凝土压缩强度的影响;Lyu^[17]采用正余弦算法优化的支持向量机模型对圆柱形混凝土的轴向承载力进行了预测。人工神经网络(ANN)具有强大的回归、模式识别能力,非常适合用于预测混凝土抗压强度^[18-19]。

本文利用 ANN 模型对加入高炉矿渣、粉煤灰的混凝土 28 d 抗压强度进行了预测,研究隐含层数、传递函数类型和优化算法等网络参数对混凝土抗压强度预测精度的影响,为混凝土力学性能的优化提供理论指导。

1 试验

1.1 原材料

本文所用水泥为海螺牌 42.5 级普通硅酸盐水泥,其物理性能如表 1 所示;细骨料为河砂,由河北宝廷工程建设有限公司提供,粒径小于 5 mm,表观密度为 2532 kg/m³,松散堆积密度 1415 kg/m³;粗骨料为花岗岩碎石,由麻城市东吴石业有限公司提供,粒径为 7 mm~32 mm,表观密度为 2481 kg/m³,堆积密度为 1289 kg/m³;高炉矿渣,由天津市燕东矿产品有限公司提供,粒径 200 目,成分见表 2;粉煤灰,由石家庄本诺矿产品有限公司提供,粒径为 325 目,堆积密度 670 kg/m³,压缩堆积密度 890 kg/m³,成分见表 2;减水剂为氨基磺酸系列减水剂,由山东同盛建材有限公司提供,密度在 1.13 kg/L~1.18 kg/L;水采用自来水。

表 1 水泥物理性能

Table 1 Physical properties of cement

比表面积 /(m ² /kg)	密度 /(kg/m ³)	标准稠度 用水量/%	凝结时间/min		抗压强度/MPa		安定性
			初凝	终凝	3 d	28 d	
331	2946	25.6	264	339	24.4	44.7	合格

表 2 高炉矿渣和粉煤灰的化学组成

Table 2 Chemical components of blast-furnace slag and fly ash

种类	CaO	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃
高炉矿渣	33.01	35.24	17.22	13.54
粉煤灰	4.11	55.92	28.29	3.88

1.2 试验方案

按照表 3 的试验方案制备不同配合比的混凝土试件。首先称量一定质量的粗骨料、细骨料、水泥、高炉矿渣、粉煤灰放入搅拌机中,混合

研究与应用

5 min, 然后加入一定量的自来水, 继续搅拌 5 min, 随后加入减水剂, 继续搅拌 3 min。将搅拌好的物料注入模具中, 放于振动台上振动 3 min, 静置 1 d 后拆模。然后将混凝土试件置于养护箱

中, 在标准养护条件下 (温度 $(20 \pm 2)^\circ\text{C}$ 、相对湿度 95% 以上) 养护 28 d, 得到 $150\text{ mm} \times 150\text{ mm} \times 150\text{ mm}$ 的方形试件。

表 3 单位立方米混凝土中各组分的质量及强度
Table 3 Components mass and compressive strength in 1 m^3 concrete

编号	各组分质量/kg							抗压强度/MPa
	水	水泥	细骨料	粗骨料	高炉矿渣	粉煤灰	减水剂	
1	132.98	306.05	867.37	865.76	16.13	191.07	20.59	51.02
2	155.97	376.93	818.11	815.99	19.88	179.85	16.49	54.96
3	179.93	446.75	767.59	766.22	23.63	168.96	11.71	51.02
4	141.01	290.83	867.37	865.76	15.38	191.07	18.31	45.01
5	164.01	360.13	818.11	815.99	18.75	179.85	14.10	52.00
6	188.94	427.85	767.59	766.22	22.50	168.96	9.40	52.99
7	151.96	206.83	892.63	891.04	10.88	196.02	13.61	27.98
8	164.98	237.80	867.37	865.76	12.38	191.07	11.71	33.00
9	191.01	300.80	818.11	815.99	15.75	179.85	7.50	34.97
10	217.05	362.75	767.59	766.22	19.13	168.96	2.91	38.02
11	138.38	296.08	887.58	864.97	15.75	168.96	15.43	57.92
12	162.76	363.28	837.06	815.99	19.13	159.39	10.70	66.35
13	182.43	430.48	787.80	767.01	22.50	149.82	10.65	66.70
14	138.38	296.08	887.58	864.97	15.75	168.96	15.43	57.65
15	162.76	363.28	837.06	815.99	19.13	159.39	10.70	61.15
16	182.43	430.48	787.80	767.01	22.50	149.82	10.65	63.03
17	138.38	296.08	887.58	864.97	15.75	168.96	15.43	34.08
18	162.76	363.28	837.06	815.99	19.13	159.39	10.70	45.82
19	182.43	430.48	787.80	767.01	22.50	149.82	10.65	50.57
20	155.97	401.08	1050.50	616.91	21.00	144.87	13.69	62.85
21	146.00	364.85	1083.34	636.66	19.13	150.15	13.53	60.79
22	123.01	328.10	1117.44	655.62	16.88	154.11	27.17	57.02
23	162.07	257.23	1122.50	660.36	13.88	155.10	7.69	45.19
24	153.06	228.88	1152.81	676.95	12.00	159.06	7.25	41.07
25	144.06	201.05	1181.86	694.33	10.88	163.02	6.38	32.46
26	174.95	192.13	1141.44	669.84	157.13	9.90	5.30	22.24
27	164.98	170.08	1166.70	685.64	160.88	8.91	5.14	21.08
28	155.00	146.98	1194.49	700.65	165.00	7.92	4.65	21.26
29	188.94	365.90	780.22	834.95	52.88	104.94	7.80	64.46
30	188.94	330.20	826.95	834.95	46.88	94.05	8.48	54.42

1.3 抗压强度测试

按照 GB/T 50081—2002《普通混凝土力学性能试验方法标准》的规定, 在 JB 67-200A 万能试验机上测试 28 d 抗压强度, 每个混凝土组成测试 3 次, 取平均值作为 28 d 抗压强度。

2 ANN 建模

人工神经网络是一种类似于人类神经系统的信息处理技术, 由大量的神经元相互连接进行计算, 根据输入数据, 通过不同算法调整神经元

之间的连接权值和偏置以改变自身结构来预测输出, 最终在输入与输出之间建立非线性连接, 其结构如图 1 所示。图中 I 表示输入层神经元 (用下标区分不同输入神经元, 下同), J 和 K 表示不同的隐含层神经元, L 表示输出层神经元, ω_{ij} 表示输入层第 i 个神经元与隐含层第 j 个神经元之间的权重, ω_{jk} 表示第一个隐含层第 j 个神经元与第二个隐含层第 k 个神经元之间的权重, ω_{kl} 表示第二个隐含层第 k 个神经元与输出层第 l 个神经元之间的权重, F 表示隐含层神经元的传递函数, θ 表示隐含

层神经元的偏置。本文的 ANN 建模采用 Matlab R2017 中的 nnstart 工具箱进行计算。

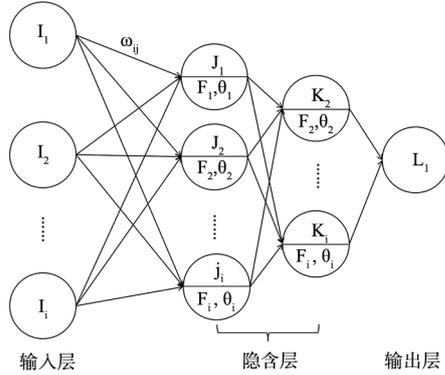


图 1 人工神经网络结构图

Fig. 1 The structure of artificial neural network

人工神经网络的建模过程如下：

① 数据预处理：在利用表 3 所示的试验数据对网络进行训练之前，需要将其按照式 (1) 和 (2) 进行归一化处理，以便于计算；

$$X_i = \frac{x_i - x_{i, \min}}{x_{i, \max} - x_{i, \min}} \quad (1)$$

式中 x 为输入变量； X 为归一化输入变量；下标 i 为不同输入变量数据， $x_{i, \min}$ 为输入变量最小值； $x_{i, \max}$ 为最大值。

$$Y_i = \frac{y_i - y_{i, \min}}{y_{i, \max} - y_{i, \min}} \quad (2)$$

式中 y 为输出变量； Y 为归一化输出变量；下标 i 为不同输出变量数据； $y_{i, \min}$ 为输出变量最小值； $y_{i, \max}$ 为最大值。

② 确定网络结构：输入变量为 7 个，即单位体积混凝土中水、水泥、细骨料、粗骨料、高炉矿渣、粉煤灰和减水剂用量，输出变量为 1 个，即 28 d 抗压强度；隐含层数、隐含层中神经元个数为需要优化的变量；隐含层的传递函数类型也需要优化，常用函数有 *logsig*、*purelin* 和 *tansig*，如式 (3) ~ (5) 所示；损失函数为均方误差 (*MSE*)，如式 (6) 所示，式中 n 为试验次数， Y 为输出值，下标 p 为网络预测值， i 为试验值；设定模型截断误差为 10^{-2} 或者最大迭代次数为 10^4 次；初始权重和偏置值随机设置。

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\text{purelin}(x) = x \quad (4)$$

$$\text{tansig}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_p - Y_i)^2 \quad (6)$$

③ 将所有试验数据按照 70/15/15 的比例分为训练、验证和测试数据集，将训练数据集输入网络中，按照 $\sum \omega \times x + \theta$ 计算下一层网络中神经元的输入，利用传递函数计算神经元输出，将结果传递到下一个神经元，直至得到预测的输出值；

④ 利用式 (6) 计算损失函数，根据反向传播算法 (*BP*)，按照 $\omega_{\text{new}} = \omega_{\text{old}} + \eta \times \delta \times \mu$ 来更新权值，式中 η 为学习率， δ 为局部梯度， μ 为上一层神经元的输出值，偏置值的更新方法与权值类似；

⑤ 返回步骤③重复上述过程，直到满足停止训练的条件，即损失函数小于截断误差或者迭代大于最大迭代次数，停止计算，网络训练完成；

⑥ 将验证数据输入网络，根据损失函数判断网络的泛化能力，是否存在过拟合现象，如果存在，则调整隐含层数和隐含层神经元个数，重新训练。

3 试验结果分析

3.1 隐含层数对 ANN 预测精度的影响

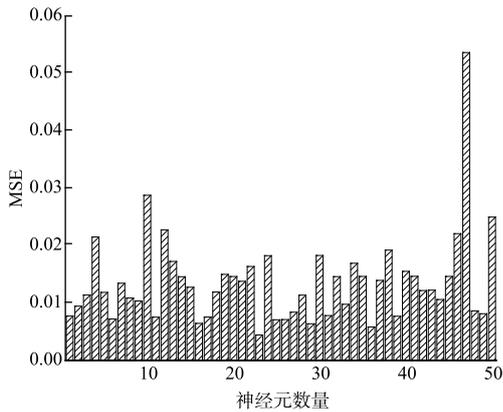
ANN 中的隐含层对输入数据进行处理，然后传输到输出层得到预测结果，其层数以及每层神经元个数对预测精度影响显著，需要对这两个网络结构参数进行优化，多数研究者采用试差法^[20]。

一般来说，单层 *ANN* 网络就可以对任何函数进行逼近，增加隐含层数或者每一隐含层神经元个数都能提高 *ANN* 的预测精度。本文对隐含层数为 1、2、3 的 *ANN* 结构进行优化，不同隐含层数对混凝土 28 d 抗压强度预测值 *MSE* 的影响如图 2 所示。

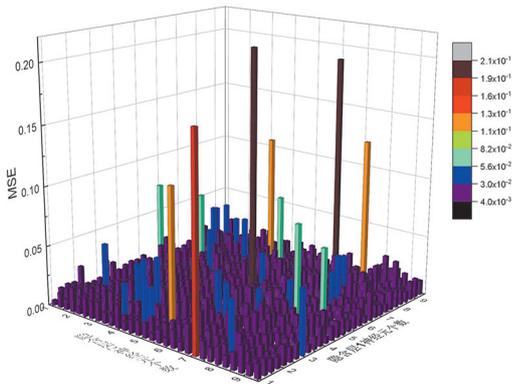
从图 2 可以看到，*ANN* 隐含层数对混凝土 28 d 抗压强度影响显著。当 *ANN* 为单一隐含层时，*ANN* 预测抗压强度的 *MSE* 在 0.0044 ~ 0.0536 之间，但隐含层为两层时，预测抗压强度的 *MSE* 在 0.0041 ~ 0.2113 之间，当隐含层为 3 层时，*MSE*

研究与应用

在 0.0037 ~ 0.4367 之间。从不同隐含层数 ANN 预测的抗压强度 MSE 下限可以看到，随着隐含层数量的增加，抗压强度预测精度略有提高，而上限值却显著增大，同时计算时间从单一隐含层的 5.61 s 增加到三个隐含层的 525.85 s，说明在本文的建模中采用单一隐含层的 ANN 就能很好建立混凝土中各组分含量与 28 d 抗压强度的非线性关系，因此接下来的计算中均采用单一隐含层 ANN 来建模。



(a) 单层



(b) 两层

图 2 ANN 隐含层数量对抗压强度预测值 MSE 的影响
 Fig. 2 The effects of hidden layer number in ANN on MSE of predicted compressive strength

从图 2 (a) 可以看到，在单一隐含层 ANN 中，隐含层中神经元个数对预测抗压强度的 MSE 影响显著。隐含层中神经元个数过少（如小于 15）或者过多（如大于 35）时，抗压强度的 MSE 均较大，神经元个数过少导致的误差增加是由于 ANN 欠拟合所致，也就是说难以准确描述输入与输出

的关系；而神经元个数过多导致的误差增加则是由于过度拟合造成的，不利于 ANN 的泛化。当单一隐含层中神经元个数为 23 时，ANN 预测混凝土抗压强度的 MSE 最低，为 0.00440。根据对 ANN 中隐含层数和神经元个数的优化，可以看到最优的 ANN 网络结构为 7-23-1（输入层-隐含层-输出层神经元个数），如图 3 所示。

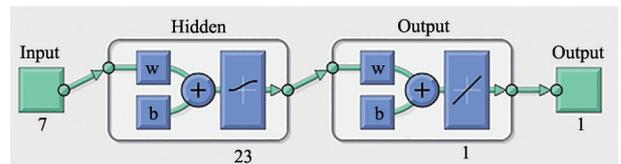


图 3 最优 ANN 网络结构
 Fig. 3 The optimal structure of ANN

3.2 传递函数对 ANN 预测精度的影响

在人工神经网络应用时最常用的传递函数包括线性函数 purelin，两种 S 型函数 logsig 和 tansig，tansig 函数，如式 (3) ~ (5) 所示。

为了研究传递函数对混凝土 28 d 抗压强度预测值 MSE 的影响，本文在隐含层和输出层采用上述三种传递函数进行 ANN 网络结构优化，传递函数对预测的抗压强度 MSE 的影响如图 4 所示。

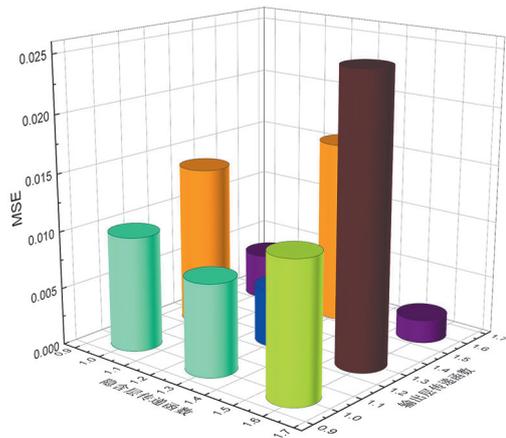


图 4 隐含层和输出层传递函数对预测抗压强度 MSE 的影响
 Fig. 4 The effects of hidden and output layer transfer function on MSE of predicted compressive strength

从图 4 可以看出，隐含层和输出层传递函数对混凝土抗压强度预测值的 MSE 影响显著，尤其是输出层，相对来说，当输出层采用 purelin 函数时，ANN 网络预测的抗压强度 MSE 较低，当隐含层和输出层同时采用 purelin 函数时，抗压强度预

测值的 MSE 最低，达到了 0.0047。而输出层采用 tansig 和 logsig 函数时预测值的 MSE 均较高，尤其是 tansig 函数，即使当隐含层采用 purelin 函数，输出层采用 tansig 函数时，预测值的 MSE 最高，达到了 0.0271，可能是由于 tansig 函数可以将输出限制在 $[-1, +1]$ 区间所致，因为当隐含层采用 purelin 函数，输出层采用 logsig 函数（输出限制在 $[0, +1]$ 区间）时，预测值的 MSE 从最高的 0.0271 降低到了 0.0128。

3.3 优化算法对 ANN 预测精度的影响

人工神经网络常用的优化方法包括：Levenberg - Marquardt、贝叶斯正则化（Bayesian Regularization）、量化共轭梯度（Scaled Conjugate Gradient）等多种算法，本文研究了如下 11 种算法，即 trainlm（LM 算法）、trainbfg（拟牛顿反向传播算法）、trainbr（贝叶斯正则化算法）、traingb（Powell-Beale 共轭梯度反向传播算法）、traingf（Fletcher-Powell 变梯度反向传播算法）、traingp（Polak-Ribiere 变梯度反向传播算法）、traingd（梯度下降反向传播算法）、traingda（自适应学习率的梯度下降反向传播算法）、traingdm（附加动量因子的梯度下降反向传播算法）、traingdx（自适应学习率并附加动量因子的梯度下降反向传播算法）、trainscg（量化共轭梯度算法），对混凝土预测抗压强度 MSE 的影响，如图 5 所示。

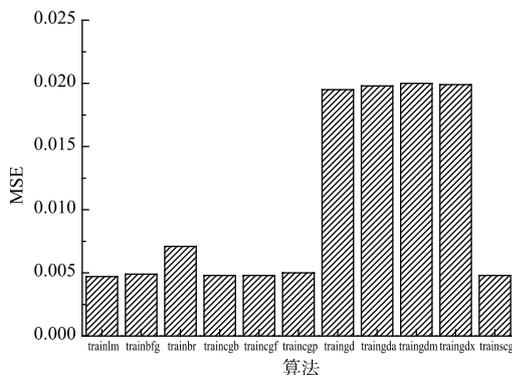


图 5 优化算法对预测抗压强度 MSE 的影响

Fig. 5 The effects of algorithm on MSE of predicted compressive strength

从图 5 可以看到，不同算法对 ANN 预测抗压强度的 MSE 影响显著。其中 trainlm、trainbfg、traingb、traingf 和 trainscg 预测值的 MSE 较小，

在 0.0048 以下，而 traingd、traingda、traingdm 和 traingdx 预测值的 MSE 较大，在 0.02 左右，说明本文的非线性系统不适合采用自适应学习率或者附加动量因子的优化算法，这可能是由于本文的数据变化缓和，没有起伏的峰谷所致。因此，采用最常用的 LM 算法就能得到较好结果，而且计算效率高，仅需 0.29 秒就能完成计算。

3.4 ANN 预测混凝土抗压强度

根据前文对 ANN 网络结构进行的优化，发现单一隐含层的 7-23-1 网络结构、隐含层和输出层均采用 purelin 传递函数、采用 trainlm 算法进行计算，可以建立结构最佳的 ANN 网络。接下来，采用这一网络对混凝土 28 d 抗压强度进行预测，并进行网络验证和测试。

从图 6 可以看出，随着 ANN 网络的不断迭代，训练、验证和测试阶段预测值的 MSE 不断降低，仅需 3 个历元（epoch）网络预测结果就能达到最优。

从图 7 可以看出，在训练、验证和测试阶段，ANN 预测结果与试验结果回归曲线斜率均大于 97%，表明两者十分吻合。从图 8 的误差棒状图可以清楚看出，ANN 预测结果偏差主要集中在 0 点附近，随着偏离 0 点距离的增加，预测结果与试验结果偏差迅速下降。

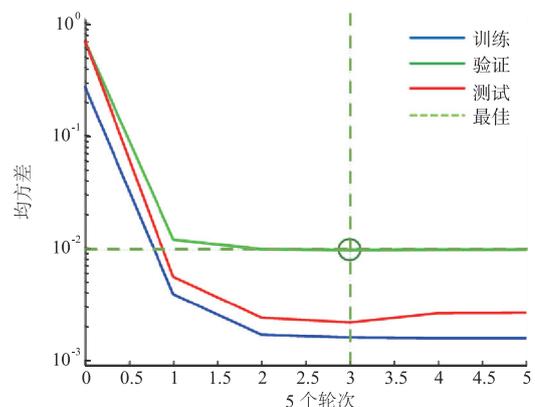


图 6 迭代过程中 MSE 随历元变化曲线

Fig. 6 The curves of MSE with epoch during iteration

研究与应用

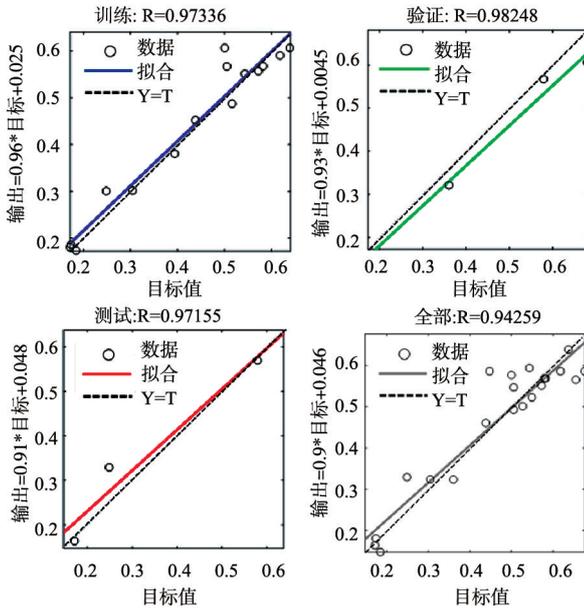


图7 网络训练、验证和测试阶段预测值与试验值的回归曲线
Fig. 7 Regression curves of the predicted and tested values during the training, validation and testing phases of the network

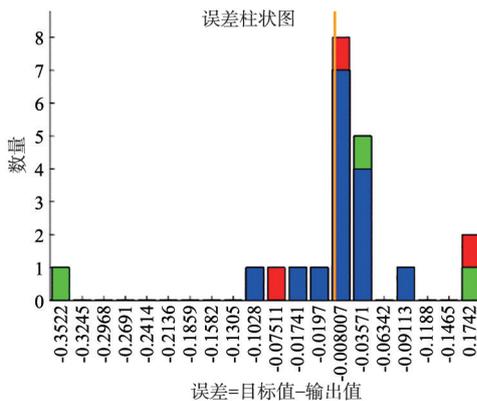


图8 预测值与试验值的误差棒状图

Fig. 8 Bar chart of error between predicted and tested values

从图6~8可以看出,本文提出的ANN模型可以很好地描述混凝土各组分含量与28d抗压强度的非线性关系,并成功预测了抗压强度值,预测结果的MSE可低至0.004左右。

4 结论

本文以水、水泥、粗细骨料、高炉矿渣、粉煤灰、减水剂为原料制作了混凝土,提出了一种预测28d抗压强度的ANN模型,研究了ANN模型中隐含层数、传递函数类型和优化算法对抗压强度预测结果的影响,得出了以下结论:

(1) ANN隐含层数对预测抗压强度的MSE影响显著。单一隐含层时,预测抗压强度的MSE在0.0044~0.0536之间,隐含层为两层和三层时,MSE分别在0.0041~0.2113和0.0037~0.4367之间,随着隐含层数量的增加,ANN预测的抗压强度MSE的下限略有降低,采用单一隐含层的ANN就能很好地预测抗压强度。

(2) 隐含层和输出层的传递函数对抗压强度预测值的MSE影响显著。当隐含层和输出层同时采用purelin函数时,抗压强度预测值的MSE最低为0.0047;当隐含层采用purelin函数,输出层采用tansig函数时,预测值的MSE最高,达到了0.0271。

(3) 优化算法对ANN预测抗压强度的MSE影响显著。trainlm、trainbfg、traincgb、traincgf和traincsg预测值的MSE较小,均在0.0048以下,不宜采用自适应学习率或者附加动量因子的优化算法。

(4) 经过优化的ANN仅需3个历元就能很好预测混凝土抗压强度,预测结果与试验结果回归曲线斜率均大于97%,预测结果的MSE低至0.004左右,两者非常吻合。

参考文献

- [1] 朱效荣, 赵志强. 智能+绿色高性能混凝土 [M]. 北京: 中国建材工业出版社, 2018: 21-30.
- [2] PER. J. Concrete and sustainability [M]. 北京: 化学工业出版社, 2013: 69-83.
- [3] 赵杨, 陈晨, 孙海燕, 等. 增效剂对混凝土性能影响的试验研究 [J]. 粉煤灰综合利用, 2021, 35 (3): 78-82.
- [4] 丘丽妹. 固废材料对混凝土性能的影响探讨 [J]. 江西建材, 2021, 7: 21-22.
- [5] 徐少成. 干硬性混凝土配合比及力学性能研究 [J]. 安徽建筑, 2021, 28 (8): 249-251.
- [6] 王军. 不同掺量的钢纤维对混凝土力学性能的影响研究 [J]. 江西建材, 2021, 7: 35-38.
- [7] 葛培, 黄炜, 权文立, 等. 混杂再生骨料混凝土抗压计算研究 [J]. 华中科技大学学报 (自然科学版), 2021, 49 (5): 86-91.
- [8] 徐存东, 黄嵩, 刘子金, 等. 盐冻作用下混凝土力学性能研究及灰色预测 [J]. 混凝土与水泥制品, 2021, 5: 6-10.

- [9] 高毅轩, 王辉明, 刘晋. 基于 M-T 均匀化理论的玄武岩纤维混凝土弹性模量和抗压强度分析 [J]. 科学技术创新, 2021, 14: 156-159.
- [10] 凌建军. 高强度玄武岩机制砂混凝土抗压强度及非线性预测模型研究 [J]. 水利与建筑工程学报, 2021, 19 (3): 124-130.
- [11] 韩笑. 基于高阶块体元-有限元建模的混凝土微观数值分析 [J]. 粉煤灰综合利用, 2021, 35 (3): 56-62.
- [12] ABHILASH P T, SATYANARAYANA P V V, THARANI K. Prediction of compressive strength of roller compacted concrete using regression analysis and artificial neural networks [J]. Innovative Infrastructure Solutions, 2021, 6 (4): 218-227.
- [13] IAN G, YOSHUA B, AARON C. Deep Learning [M]. 北京: 人民邮电出版社, 2017.
- [14] MARTIN T H, HOWARD B D, MARK H B, et al. Neural network design [M]. 北京: 机械工业出版社, 2018.
- [15] LATIF S D. Developing a boosted decision tree regression prediction model as a sustainable tool for compressive strength of environmentally friendly concrete [J]. Environmental Science and Pollution Research, 2021.
- [16] SALAMI B A, OLAYIWOLA T, OYEHAN T A, et al. Data-driven model for ternary-blend concrete compressive strength prediction using machine learning approach [J]. Construction and Building Materials, 2021, 301: 124152.
- [17] LYU F, FAN X Y, DING F X, et al. Prediction of the axial compressive strength of circular concrete-filled steel tube columns using sine cosine algorithm-support vector regression [J]. Composite Structures, 2021, 273: 114282.
- [18] 金浏, 赵瑞, 杜修力. 混凝土抗压强度尺寸效应的神经网络预测模型 [J]. 北京工业大学学报, 2021, 47 (3): 260-268.
- [19] AL H, HAWRAA S J, et al. Artificial intelligence-based compressive strength prediction of medium to high strength concrete [J]. Iranian Journal of Science and Technology, Transactions of Civil Engineering, 2021, 14: 1-14.
- [20] 陈明. MATLAB 神经网络原理与实例精解 [M]. 北京: 清华大学出版社, 2019: 76-90.

(上接第 71 页)

- [8] 中华人民共和国住房和城乡建设部. 补偿收缩混凝土应用技术规程: JGJ/T178-2009 [S]. 北京: 中国建筑工业出版社, 2009. 2-3.
- [9] 袁学成. C40P10 大体积混凝土研究与制备 [C] //第七届全国混凝土膨胀剂学术交流论文集, 2018: 171-174.
- [10] Nguyen T C, Luu X B. Reducing temperature difference in mass concrete by surface insulation [J]. Magazine of Civil Engineering, 2019, 88 (4): 70-79.
- [11] SEO T S, KIM S S, LIM C K. Experimental study on hydration heat control of mass concrete by vertical pipe cooling method [J]. Journal of Asian Architecture and Building Engineering, 2015, 14 (3): 657-662.
- [12] 李东, 张晔琛. 混凝土水化放热模型的实验分析和计算 [J]. 上海大学学报 (自然科学版), 2021, 27 (4): 795-802.
- [13] 刘拼, 徐智丹, 张登科, 等. 大体积混凝土板式结构裂缝控制应用技术研究 [J]. 新型建筑材料, 2022, 49 (9): 35-39+43.
- [14] 刘拼, 张登科, 徐智丹, 等. 大体积混凝土侧墙裂缝控制技术应用研究 [J]. 新型建筑材料, 2022, 49 (5): 84-87+109.
- [15] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 混凝土膨胀剂: GB/T 23439-2017 [S]. 中国标准出版社, 2018.