

文章编号:1007-9629(2023)07-0705-11

基于耦合 BAS-MLP 的混凝土抗压强度预测

汪声瑞¹, 胡 畔^{1,*}, 陈思宝², 肖 约³

(1. 武汉理工大学 土木工程与建筑学院, 湖北 武汉 430070; 2. 长江勘测规划设计研究有限责任公司, 湖北 武汉 430010; 3. 华杰工程咨询有限公司 中南分公司, 湖北 武汉 430000)

摘要: 针对 1 030 组混凝土抗压强度试验数据, 通过天牛须搜寻算法(BAS)来训练多层神经网络(MLP), 并与混合复杂进化方法(SCE)-MLP、多元宇宙优化算法(MVO)-MLP 这 2 种耦合模型算法进行对比分析, 得到可用于预测混凝土抗压强度的算法模型。结果表明: BAS 可以显著提高 MLP 的训练精度和预测精度, 该算法比 SCE-MLP、MVO-MLP 耦合模型算法更快、更准确; 与人工神经网络(ANN)和支持向量机(SVM)个体学习算法相比, 元启发式算法在混凝土抗压强度预测方便表现出良好的优越性。同时讨论了 BAS-MLP 模型中与训练数据集数量和输入变量数量相关的因素, 发现使用 1 030 组数据的 80% 即可获得良好的预测结果。

关键词: 混凝土; 抗压强度; 耦合; 预测; 学习算法; 训练数据集

中图分类号: TU528.1

文献标志码: A

doi: 10.3969/j.issn.1007-9629.2023.07.002

Prediction of Concrete Compressive Strength Based on Coupled BAS-MLP

WANG Shengrui¹, HU Pan^{1,*}, CHEN Sibao², XIAO Yue³

(1. School of Civil Engineering and Architecture, Wuhan University of Technology, Wuhan 430070, China;

2. Changjiang Survey Planning Design and Research, Co., Ltd., Wuhan 430010, China;

3. Zhongnan Branch, Huajie Engineering Consulting Co., Ltd., Wuhan 430000, China)

Abstract: 1 030 sets of concrete compressive strength test data were used to train the multilayer perceptron(MLP) through beetle antennae search algorithm(BAS) and combined with shuffled complex evolution(SCE), multi-verse optimizer(MVO) and the results of two MLP coupling algorithms were compared and analyzed, and an algorithm model that can be used to predict the compressive strength was obtained. The results show that BAS can significantly improve the training accuracy and prediction accuracy of MLP, and this model is faster, more accurate and stable than the other two coupled model algorithms. Compared with artificial neural network(ANN) and support vector machine(SVM) individual learning algorithms, the prediction of concrete compressive strength shows the superiority of meta-heuristic algorithm. The factors related to the number of training data sets and the number of input variables in the BAS-MLP model are discussed, and it is found that using 80% of the 1 030 sets of data can obtain good prediction results.

Key words: concrete; compressive strength; coupling; prediction; learning algorithm; training data set

在建筑工程中, 混凝土的抗压强度取决于两方面: 一是正确的配合比设计, 二是规范的施工和养护。在实际施工过程中, 由于不同操作者的主观判断和

操作方式不一, 加上环境条件的变化, 使得混凝土实测 28 d 抗压强度往往有所差别。能否准确预测混凝土的 28 d 抗压强度, 是保证正常施工速度和减少返

收稿日期: 2022-09-26; 修订日期: 2023-01-05

基金项目: 中国工程院咨询研究基金资助项目(2019-XZ-19)

第一作者: 汪声瑞(1955—), 男, 湖北武汉人, 武汉理工大学副教授, 硕士生导师, 学士。E-mail: WSR_012@126.com

通讯作者: 胡 畔(1994—), 男, 湖北武汉人, 武汉理工大学工程师, 博士。E-mail: 1204209248@qq.com

工的重要保证^[1]。当前,通常采用水灰比作为主线性函数来进行普通混凝土抗压强度值的描述和预测^[2],但该过程费时且繁琐,成本较高,因此对混凝土抗压强度进行迅速而准确地预测显得十分重要。

近年来,国内外学者在混凝土抗压强度预测方面作了大量探索,不少学者开始使用机器学习来分析混凝土抗压强度与相关因素之间的关系^[3-6]。Pham等^[7]提出采用最小二乘支持向量回归(LS-SVR)与萤火虫算法(FA)的组合来预测高性能混凝土抗压强度。Tiberti等^[8]采用M5P算法,通过高维度数据构建模型树研究了高性能混凝土抗压强度预测。Venkateshwaran等^[9]通过Bagging集成算法研究3种替代材料对高性能混凝土抗压强度的影响。Bui等^[10]成功采用优化改进后的FA算法与人工神经网络(ANN)设置了权值和阈值。Tien等^[11]比较了鲸鱼优化算法(WOA)、蜻蜓算法(DA)与蚁群优化算法(ACO),发现三者预测混凝土28d抗压强度方面均具有高效率优化性能,这些算法与ANN相结合,还优化了权值和阈值。Duan等^[12]测试了各种机器学习工具和自适应模糊神经网络(ANFIS),并与独立成分分析(ICA)耦合,预测了再生骨料混凝土抗压强度。相比传统试验方法,机器学习算法能够获得更好的预测结果,但确定合适的预测模型并不容易。当ANN解决高维问题时,寻优会遇到局部最小值,但当其与元启发式算法进行耦合后就可以更好地解决这类问题。

基于此,本文首先提出一种基于耦合天牛须搜寻算法(BAS)^[13]和多层神经网络算法(MLP)^[14],共

收集1030组混凝土抗压强度试验数据,以原材料含量和养护时间为输入数据,抗压强度为输出数据;然后介绍BAS-MLP的数学背景和相应的实现过程;最后利用收集到的数据训练BAS-MLP算法,得到预测混凝土抗压强度值的算法模型。将BAS-MLP与混合复杂进化方法(SCE)-MLP和多元宇宙优化算法(MVO)-MLP进行结果比较、与个体学习算法ANN和支持向量机(SVM)进行性能对比,表现出耦合后的元启发式算法方法的优越性;同时讨论了BAS-MLP方法中与训练数据集的数量和输入变量数量相关因素的影响。

1 数据资料分析

建立预测模型需要大量的混凝土抗压强度试验数据,为此采用由Yeh^[15]收集的1030组混凝土抗压强度试验数据。表1给出了混凝土抗压强度及关键因素描述性统计数据。其中前7组为每m³混凝土内各原材料(水泥(C)、高炉矿渣粉(BFS)、粉煤灰(FA1)、水(W)、减水剂(SP)、粗骨料(CA)和细骨料(FA2))用量,第8组为混凝土养护时间(t_{cur}),第9组为混凝土抗压强度(f_c)。由于这9组数据所表示的物理意义不同,为避免输入向量和输出向量的不同纲量对网络训练的影响,必须对其进行归一化处理,本试验利用MATLAB中的mapminmax函数^[16]完成。为防止MLP神经网络过度拟合,影响推广概括能力,随机选取824组(占总体80%)作为训练输入数据,206组作为仿真预测数据,用于判定它们在无经验条件下的准确性。

表1 混凝土抗压强度及关键因素描述性统计数据
Table1 Descriptive statistics data of concrete compressive strength and key factors

Parameter	Mean value	Standard error	Descriptive index			
			Sample variance	Skewness coefficient	Minimum	Maximum
$m_c/(\text{kg}\cdot\text{m}^{-3})$	281.17	3.26	10 921.74	0.51	102.00	540.00
$m_{\text{BFS}}/(\text{kg}\cdot\text{m}^{-3})$	73.90	2.69	7 444.08	0.80	0	359.40
$m_{\text{FA1}}/(\text{kg}\cdot\text{m}^{-3})$	54.19	1.99	4 095.55	0.54	0	200.10
$m_w/(\text{kg}\cdot\text{m}^{-3})$	181.57	0.67	456.06	0.07	121.75	247.00
$m_{\text{SP}}/(\text{kg}\cdot\text{m}^{-3})$	6.20	0.19	35.68	0.91	0	32.20
$m_{\text{CA}}/(\text{kg}\cdot\text{m}^{-3})$	972.92	2.42	6 045.66	-0.04	801.00	1 145.00
$m_{\text{FA2}}/(\text{kg}\cdot\text{m}^{-3})$	773.58	2.50	6 428.10	-0.25	594.00	992.60
t_{cur}/d	45.66	1.97	3 990.44	3.27	1.00	365.00
f_c/MPa	35.82	0.52	279.08	0.42	2.33	82.60

2 BAS算法与MLP耦合

2.1 BAS算法原理

BAS是一种高效的多目标函数优化寻优算法,

其生物学原理是:天牛在采食过程中需要通过它左右2根长须来判断食物气味的强弱以确定位置,进而采食。当左须感受到的气味强度强于右须时,它便朝左飞过去;反之,它就向右飞行。

2.2 数学背景

数学模型以气味为函数来描述天牛行为和天牛活动过程,分析这2个变量之间的关系后发现,只有在任意2点间的距离大于或等于该点处的气味值时才会出现全局气味值。基于此,本算法将寻优步骤以数学模型的形式表述出来,具体步骤如下。

(1)天牛朝向通过式(1)进行随机化处理。

$$\mathbf{b} = \frac{\text{rands}(k, 1)}{\|\text{rands}(k, 1)\|} \quad (1)$$

式中: $\mathbf{b}$ 为天牛须朝向的随机向量; $\text{rands}()$ 为随机函数; k 为空间维数。

(2)在每次迭代中,天牛左右须坐标为:

$$\begin{cases} x_r = x' + d_0 \times \mathbf{b}/2 \\ x_l = x' - d_0 \times \mathbf{b}/2 \end{cases} (t=0, 1, 2, \dots, n) \quad (2)$$

式中: x_r 和 x_l 分别为右须和左须在第 t 次迭代时的坐标; x' 为天牛在第 t 次迭代时的质心坐标; d_0 为两须之间的距离。

(3)建立适应度函数 $f()$ 判断左须适应度 $f(x_l)$ 和右须适应度 $f(x_r)$ 的气味强度。

$$f_{c, \text{BAS-MLP}} = -0.2105a + 0.7888b + 0.1578c - 0.2448d + 0.3008e + 0.0205f - 0.1469g - 0.6247 \quad (4)$$

式中: $f_{c, \text{BAS-MLP}}$ 为用BAS-MLP算法得到的混凝土抗压强度; a, b, c, d, e, f 和 g 为中间参数。

$$\begin{bmatrix} a \\ b \\ c \\ d \\ e \\ f \\ g \end{bmatrix} = \text{tansig} \left(\begin{bmatrix} 0.0157 & 0.7792 & 0.1151 & 1.0590 & 0.1404 & 0.4573 & 0.5877 & 0.9336 \\ -0.6563 & 0.8609 & 0.7220 & -0.2457 & -0.5198 & -0.2549 & -0.2549 & -0.9488 \\ -0.3159 & 0.5080 & -0.1876 & -1.0440 & 0.9217 & -0.6317 & -0.6317 & -0.6133 \\ -0.9955 & -0.8283 & -0.2081 & -0.9163 & 0.4844 & 0.5824 & 0.5824 & 0.2093 \\ 0.3713 & 0.7562 & 0.2550 & -0.3001 & 0.3069 & -0.2012 & -0.2012 & 1.1827 \\ -0.8547 & 0.3804 & 0.2639 & -0.7994 & -0.8513 & 0.2606 & 0.2606 & 0.1610 \\ 0.3341 & 0.6478 & 0.3851 & -0.6333 & -0.3241 & 0.9617 & 0.9617 & -0.7295 \end{bmatrix} \right) + \begin{bmatrix} m_c \\ m_{\text{BFS}} \\ m_{\text{FA1}} \\ m_w \\ m_{\text{SP}} \\ m_{\text{CA}} \\ m_{\text{FA2}} \\ t_{\text{cur}} \end{bmatrix} + \begin{bmatrix} -1.7855 \\ 1.1903 \\ 0.5952 \\ 0 \\ 0.5952 \\ -1.1903 \\ 1.7855 \end{bmatrix} \quad (5)$$

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (6)$$

图1为MLP结构及其参数图解。

2.4 BAS-MLP耦合

本文采用BAS算法搜寻MLP神经网络的最优初始权值与阈值,并将其应用到已经设定好的网络中,由此构建最终算法训练模型。它能克服MLP神

(4)迭代更新天牛的位置(x'^{+1}),其表达式如下:

$$x'^{+1} = x' - \delta' \times \mathbf{b} \times \text{sign}(f(x_r) - f(x_l)) \quad (3)$$

式中: δ' 为在第 t 次迭代时的步长因子; $\text{sign}()$ 为符号函数。

2.3 MLP原理

MLP是一种前向结构的人工神经网络,由于神经网络具有处理复杂非线性关系的优点,因此神经网络模型被引入进行混凝土强度的预测。它由多个神经元组成,每个神经元分为输入层、隐含层和输出层^[17]。其中输入层包含1个权值矩阵,通过该矩阵表示输入和输出数据之间的依赖关系;隐含层根据权值矩阵确定其相应的网络结构及其对应的隐层节点数;输出层采用MLP神经算法实现运算,最后得到预测值。

MLP神经网络内部进行的计算首先将加权输入值与输入层之间的偏差进行求和,如式(4)所示;然后将结果传递给隐藏层神经元,神经元释放的中间参数如式(5)所示;神经元内部 $\text{tansig}()$ 激活函数起着隐藏层激活的作用,如式(6)所示。

神经网络稳定性差、易陷入局部最优等问题。模型建立步骤如下:

(1)创建天牛须朝向的随机向量 搜索空间维度 $k=8 \times 7 + 7 \times 1 + 7 + 1$,设置模型结构为8-7-1即输入层、隐藏层和输出层神经元个数分别为8、7和1。

(2)步长因子 δ 的设置 δ 是对天牛进行区域搜




图1 MLP结构及其参数图解

Fig. 1 Illustration of MLP structure and its parameters

索能力的控制, δ 要尽量大, 使其覆盖当前搜索区域, 不落入局部极小, 即:

$$\delta^{t+1} = \delta^t \times 0.95, \quad t = (0, 1, 2, \dots, n) \quad (7)$$

(3) 确定目标评价函数 将均方根误差 (RMSE) 定义为目标评价函数, 进行空间区域搜索.

(4) 天牛位置初始化 初始参数取为 $[-0.5, 0.5]$ 间的随机数, 为天牛的初始位置, 保存在 best X 中.

(5) 评价 根据目标评价函数计算在初始位置时适应度函数值并其保存在 best Y 中.

(6) 更新天牛左右须位置 根据式(2)更新天牛左右须位置的坐标.

(7) 更新解 根据天牛须算法中的左右须位置, 求出左右须的适应度函数值, 并比较强度大小. 根据式(3)更新天牛位置 (调整 MLP 神经网络的权值和阈值), 再计算在当前位置下的适应度函数值. 若当前适应度函数值优于 best Y, 则更新 best Y 和 best X.

(8) 迭代停止 判断适应度函数值是否达到设定的精度 (取为 0.001), 如果满足条件, 则进入步骤 (9), 否则返回步骤 (6) 继续迭代.

(9) 生成最优解 当算法不再迭代, best X 中的解是训练的最优解, 也是 MLP 神经网络的最优初始权值和阈值. 将上述最优解进行二次训练学习, 最终形成混凝土抗压强度预测模型.

3 仿真测试

基于 BAS-MLP 神经网络进行耦合, 同时与 SCE-MLP、MVO-MLP 算法进行评价指标对比, 以检验 BAS-MLP 耦合模型效率.

3.1 评价指标

采用 3 个公认的准确度评价指标^[18]——均方根误差 (E_{RMSE})、平均绝对误差 (E_{MAE}) 和相关系数 (R^2), 来评估 MLP 的性能. 这些指标分别用式 (8)、(9)、(10) 表示.

$$E_{\text{RMSE}} = \sqrt{\frac{1}{K} \sum_{i=1}^K [(Z_{i,\text{obs}} - Z_{i,\text{pre}})]^2} \quad (8)$$

$$E_{\text{MAE}} = \frac{1}{K} \sum_{i=1}^K |Z_{i,\text{obs}} - Z_{i,\text{pre}}| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^K (Z_{i,\text{pre}} - Z_{i,\text{obs}})^2}{\sum_{i=1}^K (Z_{i,\text{obs}} - \bar{Z}_{i,\text{obs}})^2} \quad (10)$$

式中: $Z_{i,\text{obs}}$ 为第 i ($i=1, 2, \dots, n$) 个混凝土立方体试块抗压强度实际值, MPa; $Z_{i,\text{pre}}$ 为第 i ($i=1, 2, \dots, n$) 个混凝土立方体试块抗压强度预测值, MPa; K 为混凝土立方体试块数量.

E_{RMSE} 和 E_{MAE} 表示预测的误差, 数值越小代表模型构建得越好, 预测越准确. R^2 表示混凝土抗压强度实际值与预测值之间的相关性, 越接近于 1, 说明回归直线与测试值的拟合程度越好; 反之, 拟合程度越差.

3.2 使用耦合 MLP 模型训练

作为耦合模型的骨架, 确定最合适的 ANN 结构具有非常重要的意义. 本文针对学习参数测试了 10 个不同的值 (1, 2, $\dots$, 10). 结果表明, 在 1 个隐藏层中有 7 个神经元的精度最高. 采用 SCE、MVO 和 BAS 这 3 种启发式算法耦合 MLP 神经网络, 以找到最合适的权值和阈值.

群体规模是影响算法寻优的一个重要参数, 在试错过程中, 对 11 种群体规模 (包括 5、10、15、20、25、50、100、200、300、400 和 500) 的 SCE 和 MVO 进行比较. 该过程完成需要超过 1 000 次的迭代, 通过计算每次迭代时目标函数的 E_{RMSE} 来监测训练误差的变化, 计算结果如图 2 所示. 由图 2 可见: 当群体规模为 100 和 300 时, 由 SCE-MLP 和 MVO-MLP 得到的最低 E_{RMSE} (即最高准确度) 分别为 7.499 和 7.196.

BAS 算法属于单体寻优, 它是不依赖于群体规模的模型. 其通过参数的试错, 得到最佳算法参数: 迭代次数为 1 000、步长为 0.8、天牛左右两须距离为 3.

图 3 为 SCE-MLP、MVO-MLP 和 BAS-MLP 算




图2 基于SCE-MLP和MVO-MLP复杂度的灵敏度分析
Fig. 2 Sensitivity analysis based on complexity of SCE-MLP and MVO-MLP




图3 SCE-MLP、MVO-MLP和BAS-MLP算法的收敛曲线
Fig. 3 Convergence curves of SCE-MLP, MVO-MLP and BAS-MLP algorithm

法的收敛曲线.由图3可见,BAS-MLP算法可以在很少迭代中收敛,而MVO-MLP算法在多次迭代后才开始收敛.这说明,BAS-MLP算法适合解决复杂数据,如优化MLP参数.

3.3 准确度评估

对于每个样本,将混凝土抗压强度预测值和实际值之间的差值作为误差.图4显示各算法获得的训练样本计算结果及相应的直方图图中将上述3种耦合算法模型与反向传播(BP)-MLP算法进行比较.

图4中的 E_{RMSE} 显示,BP-MLP算法的训练误差为7.847,大于SCE-MLP、MVO-MLP和BAS-MLP算法的训练误差.另外,图4中的 E_{MAE} 也说明元启发式算法比BP方法更成功.

对测试数据也进行类似的过程,图5为混凝土抗压强度预测值与实际值之间的关系.由图5可见:SCE-MLP、MVO-MLP及BAS-MLP 3种模

型均获得了良好的混凝土抗压强度预测;特别是对于混凝土抗压强度峰值,BP-MLP、SCE-MLP、MVO-MLP和BAS-MLP预测的混凝土抗压强度值与实际值更加接近.在这一阶段, E_{RMSE} 值从8.975下降到8.354、7.896和7.540.与BP-MLP中的MAE相比,由SCE、MVO和BAS训练的MLP中的较小(前两者 E_{MAE} 对比值为:6.811 vs. 6.466、5.891和5.832),证明这些算法较BP更具有效性.

各算法训练结果和测试结果的相关系数如图6所示.由图6可见,通过应用SCE、MVO和BAS算法,BP-MLP的训练相关系数 R^2 从0.773上升到0.791、0.809和0.820;测试相关系数 R^2 从0.744增至0.788、0.805和0.821.以上均表明耦合模型预测的混凝土抗压强度值与实测值的相关性更强.

与BP-MLP相比,SCE、MVO和BAS的权值和阈值可以构建一个更强大的网络.此外,在训练阶段,与SCE-MLP、MVO-MLP相比,BAS-MLP的结果相关性较大、误差较小,表明该算法在训练人工神经网络时效率更高,在预测混凝土抗压强度方面也超过其他2个耦合模型.

在算法耗时方面,群体规模为100和300的SCE和MVO算法耗时分别需要约800、3 926 s,而BAS仅需要212 s内就能够优化MLP.因此,BAS算法是本研究中最有效的算法.

3.4 实例验证

通常情况下,虽然准确测试混凝土抗压强度可以通过回弹法、超声回弹综合法及钻芯法来实现的,但这些方法均具有局限性.因此需要由1个训练有素的智能算法模型进行处理,本文中的BAS-MLP算法可以帮助工程师预测不同条件下混凝土的抗压强度.

图7比较了混凝土抗压强度试验数据和BAS-MLP预测数据随养护时间的变化趋势.由图7可见,BAS-MLP算法可以很好地预测混凝土的抗压强度,预测结果与实际强度误差不大.

4 与个体学习算法间的比较

为了更好地展示BAS-MLP算法的能力,本文还将其与广泛采用的ANN与SVM个体学习算法进行了对比,结果见图8.






图4 各算法获得的训练样本计算结果及相应的直方图


Fig. 4 Calculation results and corresponding histogram obtained for the training samples from various algorithms




(a) BP-MLP



(b) SCE-MLP




(c) MVO-MLP




(d) BAS-MLP

图5 混凝土抗压强度预测值与实际值之间的关系


Fig. 5 Relationship between the predicted and actual compressive strength of concrete




(a) Training BP-MLP



(b) Testing BP-MLP



(c) Training SCE-MLP



(d) Testing SCE-MLP




图6 各算法训练结果和测试结果的相关系数

Fig. 6 Coefficient of correlation between training and test results obtained from various algorithms




图7 混凝土抗压强度试验数据和预测数据随养护时间的变化趋势

Fig. 7 Example of compressive strength trends with respect to curing age of concrete

由图8可见, BAS-MLP算法显示出更强的线性关系, 其预测值更接近测试值. 原因在于SVM或ANN是个体学习算法, 当样本过多时, 需要大量的权值和阈值, 效率不高; 而BAS-MLP是耦合后的元启发式算法, 它没有过多的参数调试, 收敛速度快、全

局寻优能力强, 能够准确、稳定地预测混凝土抗压强度.

5 模型性能分析

5.1 训练数据集数量的影响

模型的性能在一定程度上取决于训练数据的数量. 基于此, 本文尝试研究训练数据集数量的影响. 这里考虑了3种情况, 即总数据分为9-1、8.5-1.5和8-2进行训练和测试, 评价指标结果见表2.

由表2可见: 尽管这3种情况的准确率随着训练数据量的增加而增长, 但准确率均非常高; 训练数据集, 无论是9-1、8.5-1.5还是8-2, 三者的 R^2 均接近1, 即预测值和测试值之间的关系是线性的; 9-1和8.5-1.5的抗压强度RMSE分别为1.52 1.53 MPa, 而8-2的抗压强度RMSE为1.55 MPa, 说明随着训练数据量的增加, 预测偏差会减小; 如果使用超过85%的总数据进行训练, MAPE将降低到5.54%以下, 结论与测试数据集结果相似; 当测试数据数量从80%增加到90%时, R^2 从0.979增至0.982, MAPE从7.78%降至6.78%, 说明预测误差和偏差均呈现减小趋势.




图8 BAS-MLP算法与ANN和SVM个体学习算法的对比

Fig. 8 Comparison of BAS-MLP algorithm compared with ANN and SVM individual learning algorithms

表2 不同训练数据集数量的评价指标结果

Table 2 Evaluation index results for different training dataset amounts

Dataset	Evaluation index			
	R^2	E_{RMSE}	$E_{\text{MAPE}}/\%$	E_{MAE}
9-1 training	0.997	1.52	5.54	1.25
9-1 testing	0.982	2.20	6.78	1.64
8.5-1.5 training	0.997	1.53	5.54	1.26
8.5-1.5 testing	0.981	2.25	7.89	1.66
8-2 training	0.996	1.55	5.74	1.26
8-2 testing	0.979	2.26	7.78	1.66

Note: E_{MAPE} —Mean absolute percentage error.

5.2 输入变量数量的影响

输入变量数量的变化也是影响因素之一,本文考虑了6种输入组合,如表3所列.组合1是原始数据,组合6只有4种输入变量——水泥、水、粗骨料和细骨料的用量.组合2~5逐渐忽略不同的输入变量,以观察影响.6种组合的预测值与测试值的结果如图9所示.

结合表3和图9可知:组合1的结果最好,原因在于它提供了整体信息输入;组合6的性能最低,其测量值的 R^2 为0.377、 E_{RMSE} 为13.04、 E_{MAPE} 为41.30%;

由表3还可知:模型的准确性不会简单地随着输入变量数量的增加而增加,例如虽然组合2有7个输入变量,但它的精度最低($R^2=0.398$ 、 $E_{\text{RMSE}}=12.81$ 、 $E_{\text{MAPE}}=40.36\%$),这是因为未考虑最重要的输入变量——养护时间;作为比较,组合3也有7个输入变量(忽略水泥用量),其性能明显优于组合2;组合5只有5个输入变量,但包含养护时间,因此其性能优于组合2和组合6;组合4尽管只有6个输入变量,但依然是拥有最好性能的组合(组合1除外).

表3 不同输入变量组合的评价指标结果

Table 3 Evaluation index results of different of input variable combinations

Combination No.	Input variable	Evaluation index			
		R^2	E_{RMSE}	$E_{\text{MAPE}}/\%$	E_{MAE}
1	$X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8$	0.982	2.20	6.78	1.64
2	$X_1, X_2, X_3, X_4, X_5, X_6, X_7$	0.398	12.81	40.36	10.05
3	$X_2, X_3, X_4, X_5, X_6, X_7, X_8$	0.865	6.07	16.42	4.39
4	$X_1, X_2, X_4, X_6, X_7, X_8$	0.907	5.02	11.81	3.46
5	X_2, X_5, X_6, X_7, X_8	0.753	8.20	21.89	5.90
6	X_1, X_2, X_3, X_4	0.377	13.04	41.30	4.65

Note: X_1 — m_c ; X_2 — m_w ; X_3 — m_{CA} ; X_4 — m_{FA1} ; X_5 — m_{SP} ; X_6 — m_{BFS} ; X_7 — m_{FA2} ; X_8 — t_{cur} .




图9 输入变量数量对评价指标的影响

Fig. 9 Influence of number of input variables on evaluation index

6 结论

(1)对多层神经网络(MLP)采用天牛须搜寻算法(BAS)、混合复杂进化方法(SCE)及多元宇宙优化算法(MVO)这3种元启发式算法进行耦合,可获得合适的权值和阈值.3个评价指标和算法时耗分析表明,BAS-MLP算法模型较其他2个算法更能准确、有效、稳定地预测混凝土的抗压强度.

(2)BAS-MLP算法优于人工神经网络(ANN)和支持向量机(SVM)这2个个体学习算法.

(3)在BAS-MLP算法模型中,使用1030组数据的80%即可获得可接受的预测结果;养护时间、水泥用量和含水量是最重要的输入变量,对混凝土抗压强度的最终预测影响非常大.

参考文献:

- [1] 徐富强,陶有田.基于IFOA-RBF算法的混凝土抗压强度预测[J].巢湖学院学报,2014,16(6):7-11.
XU Fuqiang, TAO Youtian. On the prediction of concrete compressive strength based on the algorithm of IFOA-RBF[J]. Journal of Chaohu College, 2014, 16(6): 7-11 (in Chinese)
- [2] HENIGAL A, ELBELTGAI E, ELDWINY M, et al. Artificial neural network model for forecasting concrete compressive strength and slump in Egypt[J]. Journal of Al-Azhar University Engineering Sector, 2016, 39(11): 435-446.
- [3] CHOU J S, TSAI C F, PHAM A D, et al. Machine learning in

concrete strength simulations: Multi-nation data analytics[J]. Construction and Building Materials, 2014, 73: 771-780.

- [4] YEH I C. Analysis of strength of concrete using design of experiments and neural networks[J]. Journal Materials Civil Engineering, 2006, 18(4): 597-604.
- [5] NEHDI M, GREENOUGH T. Modeling shear capacity of RC slender beams without stirrups using genetic algorithms[J]. Smart Structure System, 2007, 3(1): 51-68.
- [6] PRAYOGO D, CHENG M Y, WIDJAJA J, et al. Prediction of concrete compressive strength from early age test result using an advanced metaheuristic-based machine learning technique[C]// Proceedings of the International Symposium on Automation and Robotics in Construction (ISARC 2017). Taipei: IAARC Publications, 2017: 34.
- [7] PHAM A D, HOANG N D, NGUYEN Q T. Predicting compressive strength of high-performance concrete using metaheuristic-optimized least squares support vector regression[J]. Computer Civil Engineering, 2016, 30(3): 06015002.
- [8] TIBERTI G, GERMANO F, MUDADU A, et al. An overview of the flexural post-cracking behavior steel fiber reinforced concrete[J]. Structural Concrete, 2017, 19(3): 695-718.
- [9] VENKATESHWARAN A, TAN K H, LI Y. Residual flexural strengths of steel fiber reinforced concrete with multiple hooked-end fibers[J]. Structural Concrete, 2017, 19(2): 352-365.
- [10] BUI D K, NGUYEN T, CHOU J S, et al. A modified firefly algorithm-artificial neural network expert system for predicting compressive and tensile strength of high-performance concrete[J]. Construction and Building Materials, 2018, 180: 320-333.
- [11] TIEN BUI D, ABDULLAHI M A M, GHAREH S, et al.

- Fine-tuning of neural computing using whale optimization algorithm for predicting compressive strength of concrete[J]. *Engineering with Computers*, 2019, 37(1):701-712.
- [12] DUAN J, ASTERIS P G, NGUYEN H, et al. A novel artificial intelligence technique to predict compressive strength of recycled aggregate concrete using ICA-XGBoost model[J]. *Engineering with Computers*, 2020, 37(4):3329-3346.
- [13] JIANG X Y, LI S. BAS:Beetle antennae search algorithm for optimization problems[J]. *International Journal of Robotics and Control*, 2018, 1(1):1.
- [14] 张涛,王才进,刘松玉. 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):382-391.
- ZHANG Tao, WANG Caijin, LIU Songyu. Prediction model of thermal resistivity of geomaterial based on artificial neural network [J]. *Journal of Building Materials*, 2020, 23(2):382-391. (in Chinese).
- [15] YEH I C. Modeling of strength of high performance concrete using artificial neural networks[J]. *Cement and Concrete Research*, 1998, 28(12):1797-1808.
- [16] 陈庆, 马瑞, 蒋正武. 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):177-183.
- CHEN Qing, MA Rui, JIANG Zhengwu. Compressive strength prediction and mix proportion design of UHPC based on GA-BP neural network[J]. *Journal of Building Materials*, 2020, 23(1):177-183. (in Chinese).
- [17] CAMPOS P G, OLIVEIRA E M J, LUDER MIR T B, et al. MLP Networks for classification and prediction with rule extraction mechanism[C]//*IEEE International Joint Conference on Networks Proceedings*. Budapest:[s.n.], 2004:1387-1392.
- [18] 刘富成. 基于随机森林和智能算法预测混凝土抗压强度的方法:112069567[P]. 2020-12-11.
- LIU Fucheng. Prediction method of concrete compressive strength based on random forest and intelligent algorithm:112069567[P]. 2020-12-11. (in Chinese)