

以粒子蜂群网络建立高性能混凝土坍落度模型

连立川^{1,2}, 刘燕妮^{1,2}, 叶怡成³

(1. 福建工程学院 土木工程学院, 福建 福州 350118;
2. 福建土木工程新技术与信息化重点实验室, 福建 福州 350118; 3. 淡江大学, 台湾 台北 251)

摘要: 以粒子蜂群算法 (particle bee algorithm, PBA) 结合神经网络 (artificial neural network, NN), 发展出一套能预测高性能混凝土 (high-performance concrete, HPC) 坍落度模型的方法。以演化运算树 (genetic operation tree, GOT) 及倒传递网络 (back-propagation network, BPN) 两种已发表的方法来比较其准确度。从模型的准确度可知, 粒子蜂群网络 (particle bee neural network, PBNN) 模型预测的准确度高于 GOT, 但接近 BPN 的准确度; 从参数的影响性可知, PBNN 显示水、强塑剂、粗骨材、细骨材、粉煤灰及水泥添加量对于 HPC 坍落度的影响性大, 而高炉矿渣粉用量对 HPC 坍落度并不敏感, 显示各项材料对于坍落度的影响仍具备高度复杂性。

关键词: 粒子蜂群算法; 高性能混凝土; 演化运算树; 倒传递网络; 粒子蜂群网络

中图分类号: TU17

文献标志码: A

文章编号: 1672-4348(2015)01-0001-09

Modelling slump model of high-performance concrete using particle bee neural network

Lien Li-Chuan^{1,2}, Liu Yan-Ni^{1,2}, Yeh I-Cheng³

(1. College of Civil Engineering, Fujian University of Technology, Fuzhou 350118, China;
2. Fujian Key Laboratory of Civil Engineering New Technology and Informationization, Fuzhou 350118, China;
3. Tamkang University, Taipei 251, Taiwan, China)

Abstract: This study used particle bee algorithm (PBA) combined with artificial neural network (NN) to predict the slump model of high-performance concrete (HPC). This study also compared the accuracy of the results with two proposed methods: genetic operation tree (GOT) and back-propagation network (BPN). The results show that particle bee neural network (PBNN) is more accurate than GOT and closer to BPN. Besides, the addition amount of the parameters such as water, super plasticizer, coarse aggregate, fine aggregate, fly ash and cement has a high influence on the slump of HPC, while the amount of blast-furnace slag has a small influence on the slump of HPC. It shows that the impacts of those materials on the slump are still a high degree of complexity.

Keywords: particle bee algorithm; high-performance concrete; genetic operation tree; back-propagation network; particle bee neural network

传统混凝土是由水、水泥、粗骨材及细骨材所组成,随着天然资源逐渐减少及环保意识日渐抬头,传统材料的取得及来源日益减少,因此替代性

或具经济性材料的使用成为混凝土工业的新趋势。又随着人口密度逐日增加,在土地有限的情况下,建筑物不得不往高处发展,因此传统的建筑

收稿日期: 2014-11-01

基金项目: 国家自然科学基金资助项目(51308120);福建省自然科学基金资助项目(56237845)

第一作者简介: 连立川(1981-),男(汉),台湾台北人,副教授,博士,研究方向:现代土木工程施工与信息化技术。

材料必须加以研发改良以配合此一趋势,于是具耐久性、体积稳定性、有高强度、工作度的高性能混凝土 (high performance concrete, HPC) 应运而生^[1-2]。高性能混凝土除了传统混凝土中的 4 种基本成份,经常加入一些填充胶结材料,例如粉煤灰 (fly ash)、高炉矿渣粉 (blast-furnace slag) 及其它化学掺剂如强塑剂 (super plasticizer, SP) 等。虽然高性能混凝土在不同的国家有不同的定义,但在本质上是强调包括高强度、高工作度、体积稳定性与耐久性等特性^[3]。

传统上,建立实验数据的模型关系式是使用统计方法,例如多变量线性回归分析 (regression analysis, RA),但是在复杂的非线性系统这种方式并不可行^[4]。一个替代的方法是倒传递网络 (back-propagation network, BPN)^[5]。BPN 模式乃其架构模仿人类大脑学习能力的计算机模式,在过去,已有相当多的研究使用 BPN 于材料的领域^[6-10]。神经网络 (artificial neural network, NN) 是一种模型的建构工具,其模型的架构是由输入层、隐藏层、隐藏节点数、输出层、内部的学习速率及惯性因子等参数所构成,而 NN 的参数架构的决定有建议的设定方式,但并没有确切的决定方式,因此,何者为最佳的模型架构将无法一一列举之,这些参数架构可以以优化算法求解之^[4]。在过去,亦有相当多的学者提出了优化算法结合模型建构工具^[4, 11-12],但这些文献注重模型构成,其模型准确性仍有待增强。遗传算法 (genetic algorithm, GA) 是人工智能中演化式计算的一门分支,其依据自然演化及适者生存的观念衍生而成^[13-14],模拟遗传的选择、交配、突变等机制。演化运算树 (genetic operation tree, GOT)^[4]、巨观进化遗传规划 (macro evolutionary genetic programming, MEGP)^[11]、语法式进化遗传算法 (grammar evolution genetic algorithms, GEGA)^[12]、及遗传算法整合回归分析 (genetic algorithms of regression analysis, GARA)^[5],皆是以 GA 为核心主轴的演化式计算方法。虽然 GA 能用来解答优化问题,但仍无法在许多高维度的数学问题取得良好的优化结果^[4]。

群智能 (swarm intelligence, SI) 算法是近几年来研究者热烈关注的研究课题之一,SI 是架构在群体的行为上,灵感来自于诸如昆虫或动物的社会行为及觅食情况。已有多种不同的群智能算

法陆续被发展出来,其中包含蚁群、鱼群、鸟群^[15]和蜂群^[16]算法。然而,这些算法皆有其优缺点,如何将算法的优点相互结合,并改善其缺点,是目前及未来的重要课题之一。学者^[17-20]发现鸟群算法有记录过去搜寻经验,并强健于局部搜寻的优点,但却有在高度离散问题下过早收敛的缺点;此外,亦发现蜂群算法有搜寻与探索的全局搜寻的优点,但其局部搜寻的能力较为薄弱,鸟群及蜂群算法的优点刚好可以互相弥补各自的缺点。有鉴于此,学者^[17-20]提出了一种改进的混合群智能优化算法,称为粒子蜂群算法 (particle bee algorithm, PBA),是模仿鸟群和蜂群的智能行为,整合各自的优势。此外,亦提出了邻近窗口 (neighbourhood windows, NW) 搜寻技术,用以提高粒子蜂群算法的搜索效率,并提出自参数更新 (self-parameter update, SPU) 的技术,以防止在高维问题上陷入局部最优解的问题。

本研究尝试建立全新的优化模式,采用 PBA 用以优化 NN 的内部参数,藉由建立粒子蜂群网络 (particle bee neural network, PBNN) 算法与套用本研究所使用之 HPC 实验数据^[4],建构 HPC 坍塌度模型,并与 GOT^[4]及 BPN^[4]两种已经被提出的方法进行比较。

1 粒子蜂群算法整合神经网络

1.1 粒子蜂群算法

本研究采用学者^[17-20]提出结合蜂群与鸟群灵感行为的粒子蜂群算法 (particle bee algorithm, PBA) 作为优化神经网络模型的算法。图 1 为粒子蜂群算法的架构。其中,粒子蜂包含 4 种,分别是侦察蜂 (n)、精英蜂 (e)、优异蜂 (b) 及随机蜂 (r)。精英蜂占侦察蜂种数的半数,剩下的半数由优异蜂及随机蜂对分。粒子蜂群算法包含 3 个参数,即精英蜂的迭代数 (Pelite) 及优异蜂的迭代数 (Pbest),最后整体的迭代数 (Bitr)。详细 PBA 运算流程介绍如下。

(1) 初始化侦察蜂

于搜寻区域内随机产生并初始设定侦察蜂位置与速度。

(2) 计算适存值

开始循环并计算侦察蜂适存值。

(3) 选出精英蜂

由侦察蜂群中选出精英蜂 (侦察蜂中拥有最

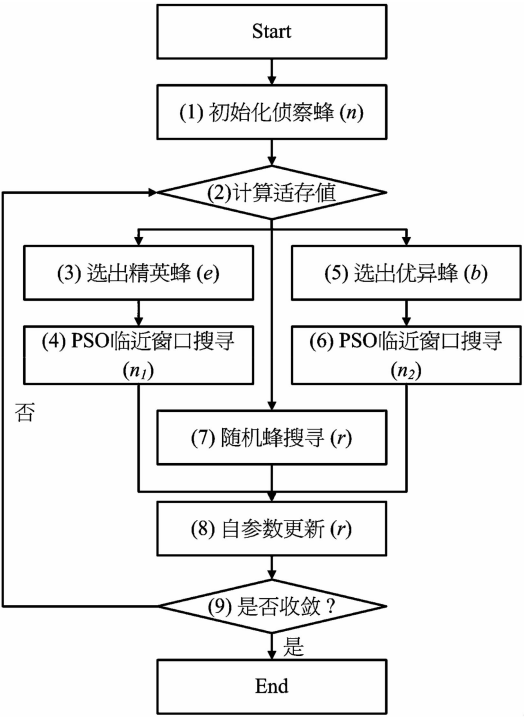


图 1 粒子蜂群算法架构

Fig. 1 The flowchart of particle bee algorithm

好的适应值),其数量为侦察蜂总数的一半。

(4)PSO 邻近窗口搜寻

运用邻近窗口技术 (neighbourhood windows, NW) 来提高 PSO 的搜寻效率,全新的粒子蜂群由精英蜂迅速更新产生。

(5)选出优异蜂

由侦察蜂群中选出精英蜂(侦察蜂中拥有次好的适应值),其数量为侦察蜂总数的四分之一。

(6)PSO 邻近窗口搜寻

运用 NW 来提高 PSO 的搜寻效率,全新的粒子蜂群由优异蜂迅速更新产生。

(7)随机蜂搜寻

在搜寻区域内随机分配随机蜂,以搜寻潜在的适应值空间,随机的随机蜂数量为侦察蜂总数的四分之一。

(8)自参数更新

精英蜂、优异蜂及随机的侦察蜂运用自参数更新技术 (self-parameter update, SPU)^[21],以防止搜寻陷入局部最佳解。

(9)是否收敛

重复这些步骤,直到满足目标值标准后停止。

1.2 神经网络

倒传递神经网络 (back-propagation network,

BPN)系现今应用最普遍且最具代表性之神经网络学习模式。其基本观念系运用最陡坡降法 (gradient steepest descent method, GSDM)之观念,将误差函数最小化。最陡坡降法的原理可应用优化算法来取代之,其整合神经网络的模式大致包含下列 4 种模式^[4]:

- 输入层优化:以优化算法排除不重要项目,并选取较具关联性的项目,将输入项目优化筛选之。
- 隐藏层优化:以优化算法优化隐藏层层数及每层隐藏层之隐藏节点数。
- 权重值优化:以优化算法优化相互链接权重值及连结偏权值。
- 参数项优化:以优化算法优化最佳之内部学习速率与惯性因子。

1.3 粒子蜂群算法整合神经网络

本研究基于粒子蜂群遗传算法 PBA 与神经网络 NN,提出一个全新的粒子蜂群网络 (particle bee neural network, PBNN)的方法,图 2 为 11 个输入变量、1 个隐藏层、多个节点及 1 个输出变量的 NN 模型,本研究是以标准的 NN 模型架构,但优化权值大小由最陡坡降法改为以 PBA 求解,并将进行多个隐藏层节点的模型建构,藉以发展 PBNN 的方法,优化高性能混凝土 HPC 坍落度模型。




图 2 11-n-1PBNN 模型

Fig. 2 11-n-1 PBNN model

2 模型建构

2.1 实验数据收集

影响 HPC 坍落度的变量包括:水泥 (C)、粉煤灰 (FL)、高炉矿渣粉 (SL)、水 (W)、强塑剂

(*SP*)、粗骨材(*CA*)、细骨材(*FA*)、龄期(*AGE*)及坍落度(*slump*)。本研究共收集 103 笔上述变量的高性能混凝土配比数据^[4],并以随机的方式取样 78 笔数据做为模型建构的训练范例,而剩余的 25 笔数据做为验证的测试范例,以评估所产生的模型是否具备普遍性,其坍落度数据的值域及型态如表 1 所示。

表 1 坍落度数据中各变量的值域及型态
Tab.1 The ranges and properties of HPC slump parameters

变量名称	值域	单位	型态
<i>C</i>	137.0 ~ 374.0	kg/m ³	连续
<i>FL</i>	0.0 ~ 193.0	kg/m ³	连续
<i>SL</i>	0.0 ~ 260.0	kg/m ³	连续
<i>W</i>	160.0 ~ 240.0	kg/m ³	连续
<i>SP</i>	4.4 ~ 19.0	kg/m ³	连续
<i>CA</i>	708.0 ~ 1 049.9	kg/m ³	连续 自变数
<i>FA</i>	640.6 ~ 902.0	kg/m ³	连续
<i>W/C</i>	0.5 ~ 1.7	比例	连续
<i>W/B</i>	0.3 ~ 0.7	比例	连续
<i>W/S</i>	0.1 ~ 0.1	比例	连续
<i>TA/B</i>	2.4 ~ 5.6	比例	连续
<i>Slump</i>	0.0 ~ 29.0	cm	连续 因变数

其中 $W/C = (W + SP)/(C)$ 、 $W/B = (W + SP)/(C + FL + SL)$ 、 $W/S = (W + SP)/(C + FL + SL + CA + FA)$ 、 $TA/B = (CA + FA)/(C + FL + SL)$

2.2 模型建构

本研究以粒子蜂群神经网络 PBNN 的方法建立高性能混凝土 HPC 坍落度模型,这个 PBNN 的方法包括 7 个部分:

- 输入层尺度转换;
- 输入层与隐藏层节点关系;
- 隐藏层节点函数建立;
- 隐藏层节点与输出层关系;
- 输出层反尺度转换;
- PBA 内部参数设定;
- 适应度函数。

2.2.1 输入层尺度转换

由于每种变量值域的范围不一,为求正规化,进行值域 -1 ~ 1 的转换,如公式(1)所示。

$$x = \frac{X - X_{\min}}{X_{\max} - X_{\min}}(D_{\max} - D_{\min}) \tag{1}$$

其中, X 为正规化前的变量; X_{\min} 为该变数之最小值; X_{\max} 为该变数之最大值; D_{\max} 为该技术指标正规化后值域中最大值,本研究 D_{\max} 设定为 1; D_{\min} 为该变量正规化后值域中最小值,本研究 D_{\min} 设定为 -1; x 为正规化后的变量。

2.2.2 输入层与隐藏层节点关系

输入层与隐藏层节点的关系如公式(2)所示。

$$net_k = \sum_{i=1}^{N_{inp}} W_{ik} \times x_i + Bias_k \tag{2}$$

其中, net_k 是隐藏层节点的加权乘积的值; W_{ik} 是隐藏层节点与输出层之间的权值; x 是尺度化后的输入变量; $Bias$ 是隐藏层的修正偏权值。

2.2.3 隐藏层节点函数建立

本研究所使用的隐藏层节点转换函数如公式(3)所示,其目的是将值域正规化至 -1 ~ 1 之间,其转换函数图,如图 3 所示。

$$f(net_k) = \text{TANH}(net_k) \tag{3}$$




图 3 隐藏层节点之转换函数图
Fig.3 The convert function graph of hidden nodes

2.2.4 隐藏层节点与输出层关系

神经网络的输出值如公式(4)所示。

$$net_j = \sum_{k=1}^{N_{hid}} W_{kj} \times f(net_k) + Bias_j \tag{4}$$

其中, W_{kj} 是隐藏层节点与输出层之间的权值; $Bias$ 是输出层的修正偏权值。

2.2.5 输出层反尺度转换

在输出变数部分,再经由反尺度转换成真实尺度,如公式(5)所示。

$$y = \frac{(y_{old} + 1) \times (D_{\max} - D_{\min})}{2} + D_{\min} \tag{5}$$

其中, y 为反尺度化后的变量; D_{\max} 为该技术指标反尺度化后值域中最大值, 从表 1 坍落度数据中各变量的值域及形态中的 Slump 可知, 本研究 D_{\max} 设定为 29.0; D_{\min} 为该变量反尺度化后值域中最小值, 本研究 D_{\min} 设定为 0.0; y_{old} 为反尺度化前的变数。

2.2.6 PBA 内部参数设定

PBA 内部参数设定依据文献[17-20]建议, 如表 2 所示。

表 2 PBA 内部参数设定
Tab.2 The PBA parameters setting

参数	设定值
n	100
e	$n/2$
b	$n/4$
r	$n/4$
w	1.0 ~ 0.7
v	$X_{\min}/10 \sim X_{\max}/10$
$Pelite$	15
$Pbest$	9

其中, n 为群体总数; e 为精英蜂总数; b 为优异蜂总数; r 为随机蜂总数; w 为鸟群算法内部权值; v 为鸟群算法速度限制值域; $Pelite$ 为精英蜂于鸟群算法优化次数; $Pbest$ 为优异蜂于鸟群算法循环次数。

2.2.7 适应度函数

本研究以训练范例的误差均方根 (root of mean square, RMS) 最小化作为适应度函数^[4], 其 RMS 如公式(6)所示, 并以测试范例的误差均方根评估产生的预测公式是否具有普遍性。

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{Slump}_i - Slump_i)^2}{n}} \quad (6)$$

其中, \hat{Slump}_i 为第 i 笔资料的预测坍落度值; $Slump_i$ 为第 i 笔数据的实际坍落度值; n 为训练范例或测试范例之总笔数。

3 研究结果

传统神经网络是以最陡坡降法 GSDM 来决定最佳权值大小, 本研究是以 PBA 的优化能力来

决定权值及修正偏权值的大小。本研究展示 8 个输入变量, 1 个隐藏层, 1 个输出变量, 以及分别对 4 个隐藏层节点(11-4-1)、8 个隐藏层节点(11-8-1)及 16 个隐藏层节点(11-16-1)做 HPC 坍落度模型探讨。

3.1 PBNN(11-4-1)

图 4 及图 5 分别为 PBNN(11-4-1)在训练范例及测试范例之 HPC 坍落度散布图, 其训练范例与测试范例 RMS 分别是 4.65 cm 及 3.81 cm, 由图可知, 训练范例及测试范例散布图皆以 45° 方式演进, 但过于发散, 不够集中, 显示实际值与预测值差距仍大。




图 4 PBNN(11-4-1) 训练范例坍落度散布图
Fig.4 The PBNN (11-4-1) scatter diagram of training set




图 5 PBNN(11-4-1) 测试范例坍落度散布图
Fig.5 The PBNN (11-4-1) scatter diagram of testing set

3.2 PBNN(11-8-1)

图 6 及图 7 分别为 PBNN(11-8-1) 在训练范例及测试范例之 HPC 坍塌度散布图,其训练范例与测试范例 RMS 分别是 3.24 cm 及 4.20 cm,由图可知,训练范例及测试范例散布图皆以 45° 方式演进,其训练范例散布图结果较 PBNN(11-4-1) 集中,但测试范例散布图结果仍呈现较发散,显示实际值与预测值差距仍大,其准确性差于 PBNN(11-4-1)。




图 6 PBNN(11-8-1) 训练范例坍塌度散布图
Fig.6 The PBNN(11-8-1) scatter diagram of training set




图 7 PBNN(11-8-1) 测试范例坍塌度散布图
Fig.7 The PBNN(11-8-1) scatter diagram of testing set

3.3 PBNN(11-16-1)

图 8 及图 9 分别为 PBNN(11-16-1) 在训练范例及测试范例之 HPC 坍塌度散布图,其训练范例与测试范例 RMS 分别是 2.79 cm 及

4.99 cm,由图可知,训练范例及测试范例散布图皆以 45° 方式演进,其训练范例散布图结果皆较 PBNN(11-4-1) 及 PBNN(11-8-1) 集中,显示实际值与预测值差距不大,但测试范例散布图明显恶化,表示 PBNN(11-16-1) 的模式在建立 HPC 坍塌度模型的准确性上发生过度学习,显示 PBNN(11-4-1) 或 PBNN(11-8-1) 的坍塌度模型较为合理。




图 8 PBNN(11-16-1) 训练范例坍塌度散布图
Fig.8 The PBNN(11-16-1) scatter diagram of training set




图 9 PBNN(11-16-1) 测试范例坍塌度散布图
Fig.9 The PBNN(11-16-1) scatter diagram of testing set

表 3 及图 10 为与 GOT^[4] 及 BPN^[4] 2 种方法在 HPC 坍塌度模型准确度的比较。模型的准确度指对问题的预测能力,亦即 RMS 越小准确度越优。PBNN 产生之坍塌度模型在测试范例的 RMS 接近于 BPN 模型,其准确度优于 GOT,证明 PBNN

(11-4-1)模式的可行性, 尽管 PBNN 的准确性未较 BPN 优异, 且有在 PBNN(11-16-1)发现过度学习的情况, 这可能是本研究未针对 PBNN 内部参数进行调适, 后续本研究可进行 PBNN 内部参数的调整, 藉以牺牲部分计算效率, 但获得更准确的结果。

表 3 3 种方法的比较

Tab. 3 The comparison among three methods

方法	RMS/cm		准确度
	训练范例	测试范例	
GOT ^[4]	5.92	4.57	良
BPN ^[4]	2.56	3.46	最优
PBNN(11-4-1)	4.65	3.87	次优




图 10 3 种方法的准确性比较

Fig. 10 The accuracy comparison among three methods

3.4 各项变量的影响性

本研究另外以公式(7)计算 PBNN 各项变量的敏感性。其 PBNN11-4-1、11-8-1、11-16-1 的结果分别如图 11~13 及表 4~6 所示。表 7 列出各项变量于 PBNN 三种模式的影响性比较, 从表 7 可知, 各项变量对坍落度的正相关影响力依序是水、强塑剂、粗骨材及细骨材; 而负相关影响力依序是粉煤灰及水泥, 此外高炉矿渣粉用量对坍落度的影响并不敏感, 显示各项材料对于坍落度的影响仍具备高度复杂性。

$$\sum f'_k \times W_{ik} \times f'_j \times W_{kj} \tag{7}$$

其中, $f'_k = (1 + \text{TANH}(Bias_k)) (1 - \text{TANH}(Bias_k))$;
 $f'_j = (1 + \text{TANH}(Bias_j)) (1 - \text{TANH}(Bias_j))$

表 4 PBNN(11-4-1)产生坍落度模型各项变量的影响性

Tab. 4 The PBNN(11-4-1) influence analysis of slump parameters

变数	敏感分析	重要性
<i>C</i>	-0.02	-
<i>FL</i>	0.15	+
<i>SL</i>	0.26	++
<i>W</i>	0.17	+
<i>SP</i>	0.21	++
<i>CA</i>	0.60	+++
<i>FA</i>	0.55	+++
<i>W/C</i>	-0.15	-
<i>W/B</i>	0.28	++
<i>W/S</i>	0.37	++
<i>TA/B</i>	-0.74	- - -




图 11 PBNN(11-4-1)产生坍落度模型各项变量的影响性

Fig. 11 The PBNN(11-4-1) influence analysis of slump parameters




图 12 PBNN(11-8-1)产生坍落度模型各项变量的影响性

Fig. 12 The PBNN(11-8-1) influence analysis of slump parameters

表 5 PBNN(11-8-1)产生坍落度模型各项变量的影响性

Tab.5 The PBNN(11-8-1) influence analysis of slump parameters

变数	敏感分析	重要性
C	0.19	-
FL	- 1.25	- - -
SL	0.03	- - -
W	1.18	+++
SP	- 0.47	-
CA	1.43	+++
FA	1.00	+++
W/C	- 0.91	- -
W/B	0.90	+++
W/S	0.27	+
TA/B	1.08	+++

表 6 PBNN(11-16-1)产生坍落度模型各项变量的影响性

Tab.6 The PBNN(11-16-1) influence analysis of slump parameters

变数	敏感分析	重要性	变数	敏感分析	重要性
C	- 0.12	-	FA	0.29	++
FL	- 0.07	-	W/C	0.07	+
SL	- 0.08	-	W/B	- 0.48	- - -
W	0.44	+++	W/S	- 0.20	-
SP	0.02	+	TA/B	- 0.24	- -
CA	0.50	+++			

4 结论及建议

由模型准确性比较可知,PBNN 在准确性方面

参考文献:

[1] 黄兆龙. 混凝土性质与行为[M]. 台北:詹氏书局,1999.

[2] 沈得县. 含波索兰材料高性能混凝土之配比技术及力学性质研究(1)[C]//科技部 HPC 研究成果推广应用研讨会, 台北:“科技部”,1999:107-112.

[3] Chang T P, Chung F C, Lin H C. A mix proportioning methodology for high-performance concrete[J]. Journal of the Chinese Institute of Engineers,1996,19(6):645-655.

[4] Yeh I-C and Lien L C. Knowledge discovery of concrete material using genetic operation trees[J]. Expert Systems with Applications,2009,36(3):5807-5812.

[5] 叶怡成. 免疫算法于高性能混凝土配比设计多目标优化之研究(1/2)[R]. 台北:“科技部”,2004.

表 7 各变量于 PBNN 3 种模式的影响性比较

Tab.7 The influence analysis comparison among three models of PBNN

模式	C	FL	SL	W	SP	CA	FA
PBNN(11-4-1)	-	+	++	+	++	+++	+++
PBNN(11-8-1)	-	- - -	- - -	+++	-	+++	+++
PBNN(11-16-1)	-	-	-	+++	+	+++	++




图 13 PBNN(11-16-1)产生坍落度模型各项变量的影响性

Fig.13 The PBNN(11-16-1) influence analysis of slump parameters

优于 GOT 但接近于 BPN,证明 PBNN 模式的可行性,尽管 PBNN 的准确性未较 BPN 优异,这可能是本研究未针对 PBNN 内部参数进行调适,后续本研究可进行 PBNN 内部参数的调整,藉以牺牲部分计算效率,但获得更准确的结果。

由各项变量的影响性可知,PBNN 的 3 种模式可看出,与坍落度成正相关且依照关联性强弱的排名分别是水、强塑剂、粗骨材及细骨材,与坍落度成负相关且依照关联性强弱排名分别是,粉煤灰及水泥,此外,高炉矿渣粉用量与坍落度皆有呈现正或负相关关系,但关联性并不强烈,显示各项材料对于坍落度的影响仍具备高度复杂性。

- [6] Yeh I-C. Modeling of strength of high performance concrete using artificial neural networks[J]. Cement and Concrete Research,1998,28(12):1797-1808.
- [7] Yeh I-C. Modeling concrete strength with augment-neuron networks[J]. ASCE, Journal of Materials in Civil Engineering, 1998,10(4):263-268.
- [8] Yeh I-C. Design of high performance concrete mixture using neural networks[J]. ASCE, Journal of Computing in Civil Engineering,1999,13(1):36-42.
- [9] Oztas A, Pala M, Ozbay E, et al. Predicting the compressive strength and slump of high strength concrete using neural network[J]. Construction and Building Materials,2005,20:769-775.
- [10] Lin J T, Wang T, Lin X J. Prediction method of concrete compressive strength based on artificial neural network[J]. Journal of Building Materials,2005,8(6):677-681.
- [11] Chen L. A study of applying macro evolutionary genetic programming to concrete strength estimation[J]. ASCE, Journal of Computing in Civil Engineering,2003,17(4):290-294.
- [12] Chen L, Tasi C S, Chen H M. A study of applying grammar evolution to concrete strength estimation[J]. Chung Hua Journal of Science and Engineering,2004,2(2):55-62.
- [13] Davis L. Handbook of Genetic Algorithms[M]. New York: Van No Strand Reinhold,1991.
- [14] Holland J H. Adaptation in Natural and Artificial System[M]. Ann Arbor: University of Michigan Press,1975.
- [15] Kennedy J, Eberhart R C. Particle swarm optimization[C]// Proceedings of the 1995 IEEE International Conference on Neural Networks,1995,4:1942-1948.
- [16] Pham D T, Koc E, Ghanbarzadeh A, et al. The bees algorithm—a novel tool for complex optimization problems[C]// Proceedings of the Second International Virtual Conference on Intelligent Production Machines and Systems, 2006, 454-461.
- [17] Lien L C, Cheng M Y. Particle bee algorithm for tower crane layout with material quantity supply and demand optimization [J]. Automation in Construction,2014,45(9):25-32.
- [18] Lien L C, Cheng M Y. A hybrid swarm intelligence based particle-bee algorithm for construction site layout optimization [J]. Expert Systems with Applications,2012,39(10):9642-9650.
- [19] Cheng M Y, Lien L C. A hybrid AI-based particle bee algorithm (PBA) for benchmark functions and facility layout optimization[J]. ASCE, Journal of Computing in Civil Engineering,2012,26(5):612-624.
- [20] Cheng M Y, Lien L C. A hybrid AI-based particle bee algorithm (PBA) for facility layout optimization[J]. Engineering with Computers,2011,28(1):57-69.
- [21] Karaboga D, Akay B. A comparative study of artificial bee colony algorithm[J]. Applied Mathematics and Computation, 2009,214:108-132.

(责任编辑:陈雯)