

基于 PSO-BP 神经网络的混凝土抗压强度预测*

何晓凤

(淮阴工学院 电子与电气工程学院, 江苏 淮安 223003)

摘要: 为了有效提高混凝土抗压强度的预测精准度, 利用粒子群算法优化 BP 神经网络初始权值和阈值, 建立了混凝土抗压强度多因子 PSO-BP 预测模型。模型以每立方混凝土中水泥、高炉矿渣粉、粉煤灰、水、减水剂、粗集料和细集料的含量以及置放天数为输入参数, 混凝土抗压强度值作为输出参数, 不仅可以克服 BP 算法收敛速度慢和易陷入局部极值的缺陷, 而且模型的学习能力、泛化能力和预测精度都有了很大的提高。以 UCI 数据库中的 Concrete Compressive Strength 数据集为例进行仿真测试, 结果表明: PSO-BP 模型预测精度较 BP、GA-BP 模型分别提高了 8.26% 和 2.05%, 验证了 PSO-BP 模型在混凝土抗压强度预测中的有效性。

关键词: BP 神经网络; 粒子群算法; 混凝土抗压强度; 预测

中图分类号: TP391.9; TU528.1

文献标识码: A

文章编号: 1674-7720(2011)20-0087-04

Prediction of concrete compressive strength based on PSO-BP

He Xiaofeng

(Faculty of Electronic and Electrical Engineering, Huaiyin Institute of Tech., Huaian 223003, China)

Abstract: To establish BP neural network (NN) prediction model for concrete compressive strength, particle swarm optimization was used to optimize the initial weights and threshold value of the neural network, with cement, blast furnace slag, fly ash, water, superplasticizer, coarse aggregate, fine aggregate and age as the model input parameters, and concrete compressive strength as the model output parameter. The PSO-BP network model could not only overcome the limitations both the slow convergence and the local extreme values by basic BP algorithm, but also improve the learning ability and generalization ability with a higher precision. The UCI's CCS set was used to test the algorithm and the simulative results showed that the learning algorithm of BP neural network optimized by PSO has better effects. The prediction accuracy of PSO-BP forecasting model increased by 8.26% and 2.05% respectively compared with those of BP neural network and GA-BP forecasting model, which proved the effectiveness of PSO-BP forecasting method in the prediction of concrete compressive strength.

Key words: BP neural network; particle swarm optimization; concrete compressive strength; prediction

混凝土抗压强度是否符合预期规定是其质量控制的重要研究内容之一, 准确预测混凝土抗压强度对施工质量、工程进度的加快有着重要作用^[1]。对于普通混凝土的强度, 一般可以用灰水比为主要因素的线性函数来进行描述和预测。对于高掺量的粉煤灰和矿渣混凝土来说, 由于其组分的增加, 水化反应的机理还不完全明确, 影响因素更为复杂并具有交互作用, 表现为特定的非线性规律^[2]。人工神经网络(ANN)是解决非线性问题的有效手段之一, 其中 BP 网络由于结构简单、易于实现、鲁棒

性强等特点, 成为神经网络中运用较多的网络之一。但是 BP 神经网络也具有有一些固有的弱点, 如算法容易陷入局部极小点、收敛速度慢等, 限制了它的进一步应用。

粒子群优化算法(PSO)避免了梯度下降法中要求函数可微、对函数求导的过程, 采用基于种群全局搜索策略, 而且其采用的速度—搜索模型操作简单。它特有的记忆使其可以动态跟踪当前的搜索情况, 调整其搜索策略, 可大大缩短神经网络的训练时间^[3]。基于此, 本文采用粒子群算法优化 BP 神经网络的权值和阈值, 并利用训

* 基金项目: 淮安市 2010 年度科技支撑项目(SN1045); 淮阴工学院科技项目(HGC1009)

技术与方法 Technique and Method

练样本建立了混凝土抗压强度 PSO-BP 预测模型。然后利用此模型对测试样本进行预测,得到测试样本抗压强度值和误差,并将结果与 BP、GA-BP 网络进行比较,来验证该模型在混凝土抗压强度预测中的可靠性和适用性。

1 PSO-BP 模型的建立

1.1 BP 神经网络基本原理

BP(Back Propagation)神经网络是一种神经网络学习算法,全称为基于误差反向传播算法的人工神经网络,由信息的正向传播和误差的反向传播两个过程组成。输入层各神经元负责接收来自外界的输入信息,并传递给中间层各神经元;中间层是内部信息处理层,负责信息交换。根据信息变化能力的需求,中间层可以设计为单隐层或多隐层结构;最后一个隐层传递到输出层各神经元的信息,经进一步处理后,完成一次学习的正向传播,由输出层向外界输出信息处理结果。当实际输出与期望输出不符时,进入误差的反向传播阶段。隐含层中神经元的转换函数有多种,通常采用 log-sigmoid 型函数。层与层之间采用全互联的方式,以三层网络为例,其 BP 网络的拓扑结构如图 1 所示^[4]。一个具有 3 层的 BP 神经网络能够以任意精度逼近任意连续函数,具有很强的非线性映射能力以及自学习、自组织和自适应能力,因此本文选用三层 BP 神经网络。

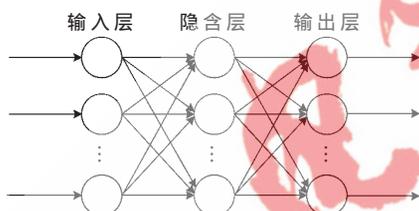


图 1 三层前馈型 BP 网络

1.2 粒子群算法基本原理

粒子群算法 PSO(Particle Swarm Optimization)的提出是受鸟群捕食行为的启发,并用于求解优化问题。该算法将每个个体看作 N 维搜索空间中的一个粒子,采取速度-位置搜索模型。假设一个 D 维的搜索空间,由 n 个粒子组成, $X=(x_1, x_2, \dots, x_n)$, 其中第 i 个粒子表示为一个 D 维的向量 $X_i=(x_{i1}, x_{i2}, \dots, x_{in})^T$, 代表第 i 个粒子在 D 维搜索空间中的位置,亦代表问题的一个潜在解。根据目标函数可计算出每个粒子位置 X_i 对应的适应度值。第 i 个粒子的速度为 $V_i=(V_{i1}, V_{i2}, \dots, V_{id})^T$, 其个体极值为 $P_i=(P_{i1}, P_{i2}, \dots, P_{id})^T$, 种群的全局极值为 $P_g=(P_{g1}, P_{g2}, \dots, P_{gd})^T$ 。

在每一次迭代过程中,粒子通过个体极值和全局极值更新自身的速度和位置,更新公式如下^[5]:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (1)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (2)$$

式中, ω 为惯性权重; $d=1, 2, \dots, D$; $i=1, 2, \dots, n$; k 为当前迭代次数; V_{id} 为粒子的速度; c_1 和 c_2 为非负的常数,称为加速度因子; r_1 和 r_2 为分布于 $[0, 1]$ 之间的随机数。

为防止粒子的盲目搜索,一般建议将其位置和速度分别限制在一定的区间 $[-X_{\max}, X_{\max}]$ 和 $[-V_{\max}, V_{\max}]$ 。

1.3 算法实现

PSO-BP 模型建立的步骤如下^[6-7]:

(1)数据预处理及网络模型参数初始化。

为了提高训练速度和灵敏度,需要对数据进行归一化处理,然后将样本划分为测试集和训练集;根据具体情况,设定 BP 网络的输入层、隐含层和输出层的神经元个数;设置粒子种群规模、维度,在允许范围内随机产生每个粒子的速度、位置。种群的规模、PSO 中粒子个数通常情况下取为几十到上百个。粒子维度 D =输入层至隐含层的连接权值个数+隐含层至输出层的连接权值个数+隐含层的阈值个数+输出层的阈值个数;粒子的速度 V_{id}^k 、位置 X_{id}^k 在给定范围内随机赋给初始值。

(2)计算每个粒子的适应度值。

先输入一个粒子,计算出所有样本的均方差,即该粒子的适应度值;同理,继续输入其他粒子,直至计算出所有粒子的适应度值。

(3)比较适应度值,确定每个粒子的个体极值点和全局最优极值点。

若 $present < P_i$, $P_i = present$, $P_i = X_{id}^k$; 否则, P_i 不变;若 $present < P_g$, $P_g = present$, $P_g = X_{id}^k$; 否则, P_g 不变。 $present$ 为当前粒子的适应度。

(4)比较适应值是否达到预设的精度。

若满足预设精度,算法收敛,最后一次迭代的全局最优值 P_g 中每一维的权值和阈值就是所要求的,直接跳到步骤(8);否则继续步骤(5)。

(5)更新惯性因子 ω 。

ω 是粒子上一次的速度对本次飞行速度的影响因子,主要用于平衡粒子群的全局搜索能力和局部搜索能力。研究表明, ω 对优化性能的影响很大,较大的 ω 值有利于跳出局部极小点,而较小的 ω 值有利于算法收敛。

(6)更新每个粒子的速度和位置。

根据式(1)、式(2)更新粒子的速度和位置,并且考虑更新后的速度和位置是否在限定的范围内。

考虑速度:若 $V_{id}^{k+1} > V_{\max}$, 则 $V_{id}^{k+1} = V_{\max}$; 若 $V_{id}^{k+1} < -V_{\max}$, 则 $V_{id}^{k+1} = -V_{\max}$;

考虑位置:若 $X_{id}^{k+1} > X_{\max}$, 则 $X_{id}^{k+1} = X_{\max}$; 若 $X_{id}^{k+1} < -X_{\max}$, 则 $X_{id}^{k+1} = -X_{\max}$ 。

(7)确定次数是否达到最大迭代次数或均方误差精度是否达到要求。若满足预测精度,则算法收敛,最后一次迭代的全局最优值 P_g 中每一维的权值和阈值即所需要的;否则返回(2),算法继续迭代。

(8)将全局最优粒子的最优值 P_g 映射为 BP 神经网络的权值和阈值,输入测试样本,检查网络的泛化能力。

技术与方法 Technique and Method

如果测试样本的适应度值符合精度要求,说明神经网络的泛化能力很好;否则,重新更改网络结构或者改变参数设置重新进行训练。

2 仿真实验

2.1 研究对象

本文的实验研究采用了 UCI 的 Concrete Compressive Strength 数据集,该数据是由台湾中华大学叶怡成教授领导的小组在实验研究中获取的^[8]。数据集中包含了 1 030 组数据,每组数据由 9 个参数组成,其中输入参数 8 个,输出参数 1 个。前 7 个输入参数是每立方混凝土中各配料的含量,包括水泥、高炉矿渣粉、粉煤灰、水、减水剂、粗集料和细集料,第 8 个输入参数是置放天数,输出参数是混凝土抗压强度,单位为 MPa。

2.2 PSO-BP 网络结构初始化

由于输入向量由 8 个参数组成,各参数具有不同的物理意义,为了避免输入或者输出向量中数值大的分量绝对误差大,数值小的分量绝对误差小,对输入、输出向量分别进行归一化处理。函数形式如下:

$$d_k = \frac{d_k - d_{\min}}{d_{\max} - d_{\min}} \quad (3)$$

其中, d_{\min} 为数据序列中的最小数; d_{\max} 为序列中的最大数,可以用 MATLAB 自带的 mapminmax 函数完成。

在确定神经网络的结构时,隐含层最佳节点数常采用试凑法,可以用如下一些经验公式^[3]:

$$m = \sqrt{r+l} + a \quad (4)$$

$$m = \log_2 r \quad (5)$$

$$m = \sqrt{rl} \quad (6)$$

式中: m 为隐含层节点数; r 为输入层节点数; l 为输出层节点数; a 为 1~10 之间的常数。

此次实验研究中经过多次试凑,将神经网络隐层节点数设定为 10,这样就建立了一个 8-16-1 的神经网络模型。因此需要 PSO 优化的权值和阈值一共有 $8 \times 16 + 16 \times 1 + 16 \times 1 = 160$ 个,粒子的维数就是 160 维。取学习 $c_1 = c_2 = 2$ 因子,种群规模 $n = 40$,采用惯性权重粒子群优化算法, ω 在 [0.4, 0.9] 之间随迭代次数的增加而线性递减, $V_{\max} = 0.5$ 。

2.3 实验结果与分析

对于 1 030 组实验数据,本文随机选取 1 020 组作为训练数据,用剩余 10 组作为测试数据。利用 Matlab 神经网络工具箱和 PSO 工具箱编制 PSO-BP 混凝土抗压强度预测程序,将 PSO 中粒子的位置映射为 BP 神经网络的初始权值和阈值,通过 BP 算法训练网络,直到网络达到性能指标。图 2 给出了 PSO 优化过程中最优个体适应度变化曲线,可见适应度值从最初的 6.5 经过 20 代左右快速收敛到了 4.5。

用训练好的 PSO-BP 模型对测试样本进行测试,得到测试样本的预测结果。图 3 给出了 10 个测试样本的预测输出,从图中可以看出,PSO-BP 模型的吻合度要比 BP、GA-BP 高许多。图 4 给出了预测相对误差,可以

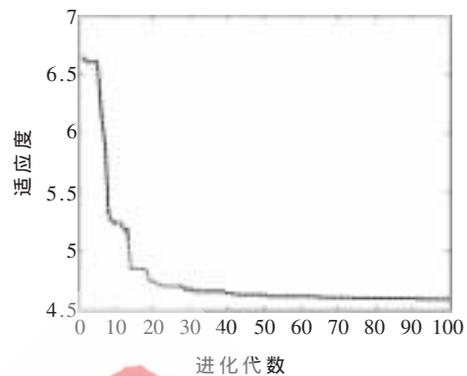


图2 最优个体适应度变化曲线

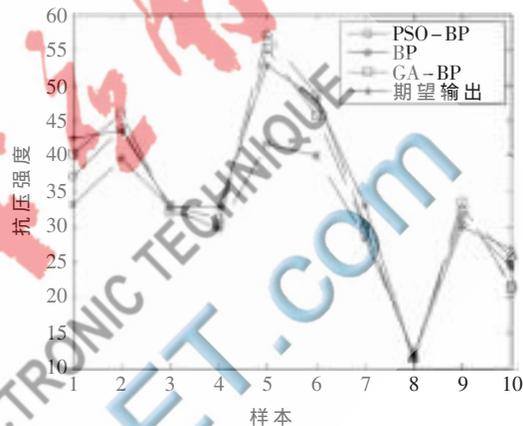


图3 PSO-BP 预测输出

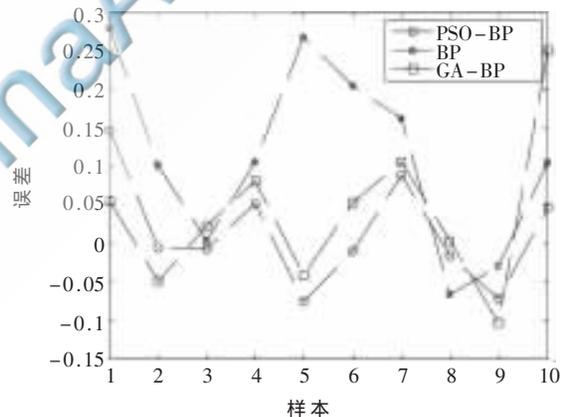


图4 PSO-BP 预测相对误差

更进一步看出,除了个别样本,PSO-BP 模型预测误差曲线在零附近的震荡和偏差都要小于 BP、GA-BP 模型。表 1 列出了 PSO-BP、BP 和 GA-BP 模型分别对 10 组测试样本的预测输出和相对误差。

观察表 1,对于 10 组测试样本,预测相对误差小于 15% 的,PSO-BP、BP 和 GA-BP 分别为 10 例、6 例和 9 例,相对误差平均值分别为 5.04%、13.30% 和 7.09%; PSO-BP 模型预测精度较 BP、GA-BP 模型分别提高了 8.26% 和 2.05%。可见,PSO-BP 模型的预测准确度要优于 BP、GA-BP,这为混凝土的抗压强度提供了一个更精准的预测方法。

技术与方法

Technique and Method

表 1 混凝土抗压强度预测结果

样本	实测/MPa	BP		GA-BP		PSO-BP	
		预测/MPa	误差/%	预测/MPa	误差/%	预测/MPa	误差/%
1	42.55	33.24	28.01	40.36	5.15	37.12	12.76
2	43.58	39.60	10.05	45.85	5.21	43.86	0.64
3	32.84	32.74	0.31	32.10	2.26	33.08	0.73
4	32.76	29.64	10.53	30.29	7.54	31.14	4.95
5	52.82	41.65	26.89	55.09	4.30	57.16	8.22
6	48.15	39.97	20.47	45.73	5.03	48.62	0.96
7	32.96	28.38	16.14	29.80	9.59	30.26	8.19
8	11.48	12.30	6.67	11.44	0.35	11.68	1.74
9	29.98	30.91	3.01	33.42	11.47	32.31	7.77
10	26.92	24.34	10.60	21.52	20.06	25.72	4.46

传统的混凝土抗压强度线性预测方法存在诸多不足,采用人工智能技术较好地解决了这个问题。将粒子群算法与 BP 神经网络相结合,建立的 PSO-BP 模型兼有人工神经网络的广泛映射能力和粒子群算法的全局收敛以及启发式学习等优点,明显提高了网络的泛化能力和运算效率。将 PSO-BP 模型运用于混凝土抗压强度预测研究中,结果表明该模型具有较高的预测精度,可以在混凝土工程中进行实际运用。

参考文献

[1] 季韬,林挺伟,林旭健.基于人工神经网络的混凝土抗压强度预测方法[J].建筑材料学报,2005,8(6):676-681.

- [2] 廖小辉,黄新,施俊玲,等.基于 BP 网络的再生混凝土抗压强度的预测模型[J].南京林业大学学报(自然科学版),2010,34(5):105-108.
- [3] 任洪娥,霍满冬.基于 PSO 优化的 SVM 预测应用研究[J].计算机应用研究,2009,26(3):867-869.
- [4] 张鹏,赵铁军,李秋义,等.双掺粉煤灰和矿渣混凝土强度的 BP 网络预测模型[J].混凝土,2009(6):16-18.
- [5] 姜伟平,陈海燕,邱新法,等.基于粒子群优化神经网络的台风灾情定量评估[J].自然灾害学报,2010,19(4):136-139.
- [6] YI D, GE X R. An improved PSO based ANN with simulated annealing technique[J]. Neurocomputing, 2005, 63(11): 527-533.
- [7] MATLAB 中文论坛编著. MATLAB 神经网络 30 个案例分析[M]. 北京:北京航空航天大学出版社,2010.
- [8] YE H I C. Modeling of strength of high performance concrete using artificial neural networks[J]. Cement and Concrete Research, 1998, 12(28): 1797-1808.
- (收稿日期:2011-07-27)

作者简介:

何晓凤,女,1982年生,本科,助教,主要研究方向:智能信息处理、人工智能识别。