

基于 PSO-ELM 的建筑物爆破震动速度预测

王新民, 万孝衡, 朱阳亚, 姜志良, 刘吉祥

中南大学资源与安全工程学院, 长沙 410083

摘要 针对影响爆破震动速度因素之间复杂的非线性关系, 利用粒子群算法(PSO)的全局搜索最优解原理和极限学习机(ELM)处理非线性关系能力, 建立了爆破震动速度预测的 PSO-ELM 模型。以某地区爆破震动实测数据为例, 选取总药量、最大段药量、爆破点与监测点距离、建筑物所在地面震动速度和测点到地面的高度等 5 个因素为输入变量, 以建筑物震动速度为输出变量。结果表明, PSO-ELM 模型训练值与预测值, 测试值与预测值的均方误差分别为 0.18 和 2.56, 平均相对误差控制在 6% 以内, 显示出该模型具有良好的训练精度和泛化能力。对比传统 ELM 模型, PSO-ELM 模型不但提高了精度和泛化能力, 而且降低了训练样本数和隐含层节点数变化对训练结果的影响, 提高了模型的拟合能力, 在类似预测工程中有一定的推广价值。

关键词 爆破震动速度; 极限学习机; 粒子群算法

中图分类号 TD853

文献标志码 A

doi 10.3981/j.issn.1000-7857.2014.19.001

Prediction for Building Vibration Velocity Caused by Blasting Based on PSO-ELM

WANG Xinmin, WAN Xiaoheng, ZHU Yangya, JIANG Zhiliang, LIU Jixiang

School of Resources and Safety Engineering, Central South University, Changsha 410083, China

Abstract Aimed at the complicated nonlinear relation between the factors influencing the blasting vibration velocity, a blasting vibration velocity prediction model is built by using the particle swarm optimization (PSO) global search optimal solution principle and extreme learning machine (ELM) ability which can deal with the nonlinear relationship. Taking blasting vibration measured data in a certain area as an example, the total dose, the explosive charge, the distance between shot and monitoring point, the ground vibration velocity and the height of the monitoring point are selected as input variables and the building vibration velocity is chosen as the output variable. The result shows that the mean square errors between training value and predicted value and between test value and predicted value are 0.18 and 2.56, respectively, and the average relative error is controlled within 6%. It is proved that the model has good precision and generalization ability. Compared with the traditional ELM model, the PSO-ELM model not only improves the accuracy and generalization ability, but also reduces the influence on the result of training when the numbers of training samples and the hidden layer nodes change, thus the fitting ability of the model is improved. This model has great a promotional value in similar predictive engineering.

Keywords blast vibration velocity; extreme learning machine; particle swarm optimization

随着爆破技术的发展, 爆破技术在矿山开采中被广泛应用^[1]。爆破时炸药爆炸产生的强大瞬间压力在岩体内引起弹性扰动向四周传播, 传到地面衰减为震动波危及爆区周边建

筑物基础甚至损坏建筑物, 爆破震动安全问题在矿山开采中越来越重要^[2,3]。在爆破震动安全分析中, 中国爆破安全规程采用震动速度作为建筑物的破坏依据^[4]。目前普遍采用萨道

收稿日期: 2014-03-10; 修回日期: 2014-05-12

基金项目: 国家科技支撑计划项目(2006BAB02A03); “十一五”国家科技支撑计划项目(2006BA02B05)

作者简介: 王新民, 教授, 研究方向为采矿及充填技术, 电子信箱: wxm1958@126.com

引用格式: 王新民, 万孝衡, 朱阳亚, 等. 基于 PSO-ELM 的建筑物爆破震动速度预测[J]. 科技导报, 2014, 32(19): 15-20.

夫斯基经验公式^[5]计算震动速度,但由于爆破震动质点速度的大小与装药量、测点到爆源的距离、装药结构和炸药性质等^[6]许多因素有关,这些因素间存在复杂的非线性关系,萨道夫斯基公式在给定基函数情况下把非线性关系简化为线性关系,在计算过程中只考虑2个主要变量,其他变量都归纳到常数中,导致爆破震动速度计算结果精度不高。因此,建立有效的爆破震动速度模型预测特定条件下爆破产生的震动速度具有重大意义。

随着系统科学、非线性科学和计算机技术的快速发展,大量现代信息处理方法被广泛应用于爆破震动速度分析预测。神经网络是近几十年发展起来的一门新兴交叉学科,它在模式识别、非线性映射方面具有独特优势。目前,不少学者将其引入到爆破震动效应的预测中,龚声武等^[7]基于模糊神经网络进行爆破震动强度预测,邵晓宁等^[8]把支持向量机算法应用于岩体爆破振动效应预测。这些算法均取得了较好的预测效果,但由于其固有的缺陷,这些算法参数设置多、学习速度慢、泛化性能差^[9]。极限学习机^[10](ELM)是一种参数设置简单且被广泛应用的神经网络算法,该算法输入层与隐含层间连接权值和隐含层神经元阈值被随机初始化给定,在训练过程中无需调整,只需要设置隐含层节点数就可获得唯一的最优解。但是极限学习机算法随机产生的隐含层参数会造成网络泛化性能较差,为了提高预测精度,需要增加隐含层节点数。而隐含层节点数过多会增加网络复杂度,容易产生过度拟合的问题。针对ELM存在的问题,刘国海等^[11]将加权最小二乘法引入到ELM中,提高了模型预测精度和稳定性;王杰等^[12]用粒子群算法(PSO)优化选择ELM的连接权值和阈值,在函数拟合实验中取得了良好的效果。粒子群算法是一种良好的全局搜索最优解算法,本文用粒子群算法优化极限学习机中的连接权值和阈值,建立爆破震动速度预测的PSO-ELM模型,提高爆破震动速度预测模型的拟合能力和精度。

1 极限学习机

1.1 极限学习机基本原理

典型的极限学习机网络由输入层、输出层和隐含层组成,输入层有 n 个输入变量,隐含层有 l 个神经元,输出层有 m 个输出变量。对于 N 个训练样本 (x_i, y_i) , $x_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T$, $y_i = [y_{i1} \ y_{i2} \ \dots \ y_{im}]^T$ ($i=1, 2, \dots, N$), 极限学习机的输入矩阵 $X = [x_1 \ x_2 \ \dots \ x_N]$, 输出矩阵为 $Y = [y_1 \ y_2 \ \dots \ y_N]$ 。设隐含层的激活函数为 $f(x)$, 则极限学习机前馈神经网络的输出可以表示为

$$\sum_{i=1}^l \beta_i f(\omega_i x_j + b_i) = t_j \quad (j=1, 2, \dots, N) \quad (1)$$

式中, β_i 为连接第 i 个隐含层节点与输出神经元的输出权值, ω_i 为连接输入神经元与第 i 个隐含层节点的输入权值, b_i 为第 i 个隐含层节点的阈值, t_j 为第 j 个训练样本的输出值。整个极限学习机网络结构如图 1 所示。




图 1 典型的 ELM 结构

Fig. 1 Structure of classical ELM

当激励函数为 $f(x)$, 含有 l 个隐含层神经元节点的前馈神经网络以零误差逼近 N 个训练样本时, 存在 β_i, ω_i, b_i 使得:

$$\sum_{i=1}^l \beta_i f(\omega_i x_j + b_i) = y_j \quad (j=1, 2, \dots, N) \quad (2)$$

式(2)可简化为

$$H\beta = Y \quad (3)$$

式中, H 为极限学习机神经网络的隐含层输出矩阵, 其表达式为

$$H(\omega_1, \omega_2, \dots, \omega_l; b_1, b_2, \dots, b_l; x_1, x_2, \dots, x_N) = \begin{bmatrix} f(\omega_1 x_1 + b_1) & f(\omega_2 x_1 + b_2) & \dots & f(\omega_l x_1 + b_l) \\ f(\omega_1 x_2 + b_1) & f(\omega_2 x_2 + b_2) & \dots & f(\omega_l x_2 + b_l) \\ \vdots & \vdots & \ddots & \vdots \\ f(\omega_1 x_N + b_1) & f(\omega_2 x_N + b_2) & \dots & f(\omega_l x_N + b_l) \end{bmatrix} \quad (4)$$

已经证明, 对于任意数量的不同样本, 当激励函数 $f(x)$ 无限可微时, 在训练中不需要调整网络参数中的输入权值 ω 和阈值 b , 且在训练中随机给出和固定不变, 隐含层输出矩阵 H 是一个确定的矩阵, 可通过求解线性方程组的最小二乘解获得输出权值:

$$\hat{\beta} = H^+ Y \quad (5)$$

式中, H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆。

1.2 极限学习机学习算法步骤

已知训练样本 (x_i, y_i) ($i=1, 2, \dots, N$), 隐含层节点个数 l , 激励函数为 $f(x)$ 时, 从以上原理可知标准单隐层前馈神经网络极限学习机的学习算法过程分为

- 1) 学习算法随机生成输入权值 ω_i 以及阈值 b_i ;
- 2) 学习算法计算隐含层输出矩阵 H ;
- 3) 学习算法计算输出权值: $\hat{\beta} = H^+ Y$ 。

2 PSO 优化的 ELM 算法

2.1 粒子群算法

粒子群算法^[13]是一种源于对简单社会系统的模拟演化而来的迭代优化算法, 于 1995 年由 Eberhart 和 Kennedy 提出。该算法中, 每个优化问题的潜在解都是搜索空间中的一只鸟, 称之为粒子。每个粒子都有一个初始化速度和位置, 一个由被优化的函数决定的适值 $F_i(i)$ 。在每一次迭代中, 粒子通过比较适值和两个极值更新自己的速度和位置: 粒子本身

所找到的最优解(个体极值 p_{best})和整个种群目前找到的最优解(全局极值 g_{best})。

在一个 D 维的目标搜索空间中,由 N 个粒子组成一个群落,其中第 i 个粒子的速度和位移为

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (6)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^k \quad (7)$$

式中, ω 为惯性权重,表示在多大程度上保留原来的速度, ω 较大,全局收敛能力强,局部收敛能力弱; ω 较小,局部收敛能力强,全局收敛能力弱。 c_1, c_2 为学习因子, r_1, r_2 为 $[0, 1]$ 范围内的均匀随机数。

该算法采用迭代方法,在同一次迭代中先比较粒子适值和个体极值大小,若 $F_i(i) > p_{best}$,则用粒子适值代替个体极值,否则接受现在的状态;同理,再拿粒子比较后的状态和全局极值比较,若 $F_i(i) > g_{best}$,用粒子适值代替全局极值,否则接受现在的状态。更新粒子的速度和位置到预期满足条件后结束迭代。将粒子群优化算法用于组合优化问题时,将目标函数作为适值函数,在粒子速度和位置范围足够大的情况下,全局搜寻最优的变量。

2.2 PSO-ELM算法

本文用粒子群算法优化 ELM 的输入权值和阈值,将 ELM 的输入权值和阈值作为粒子群算法的粒子,以训练样本的均方误差(mse)作为粒子群算法的适值函数,适值越小预测值越精确,寻找到的输入权值和阈值就越优。

粒子群算法优化 ELM 的算法步骤如下:

- 1) 初始化,随机训练得到权值和阈值,参考权值和阈值范围作为粒子速度和位置寻优范围;
- 2) 选择合适的参数,包括种群规模 M (取 100),最大迭代次数 T (取 1000),惯性权值 ω (取 0.6),学习因子 c_1, c_2 (取 $c_1 = c_2 = 2$),粒子维数 D (取 2);
- 3) 确定适值函数计算每个粒子的适值,求出每个粒子的个体极值和全局极值;
- 4) 更新粒子的速度和位置;
- 5) 迭代,直到满足停止条件(到达最大循环次数)退出,得到最优 ELM 参数。

算法流程如图 2 所示。

3 爆破震动速度预测的 PSO-ELM 模型

3.1 影响因素的确定

影响爆破震动速度的因素很多,主要与装药量、爆破距离和地质条件等有关。经验公式法基于简便性原则,采用装药量和爆心距作为主要因素,但爆破时其他一些因素对爆破震动速度也有影响。本文利用极限学习机的非线性映射能力,选取影响地面建筑物爆破震动速度的 5 个主要因素(总药量,最大段药量,爆破点与监测点距离,建筑物所在地面震动速度,测点到地面的高度),以这 5 个变量值作为 PSO-ELM 模型的输入变量,以预测建筑物震动速度作为模型的输出变量。

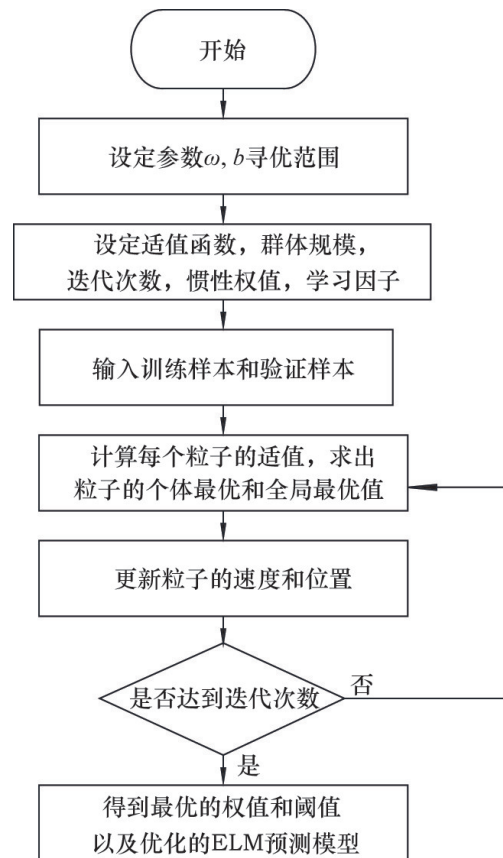


图 2 PSO-ELM 流程

Fig. 2 Flow diagram of PSO-ELM

3.2 训练样本与测试样本的选择

本文用于训练 PSO-ELM 预测模型的数据来自文献 [14]。样本总量为 28 个,样本编号及数值见表 1。为了减少样本指标差异对模型的性能影响,样本数据在输入模型前归一化到 $[-1, 1]$ 范围内,预测的建筑物震动速度数值在输出模型后反归一化。

3.3 预测模型参数设置

粒子群算法中基本参数为种群规模和最大迭代次数。种群大小不能提供足够的采样点,以致算法性能很差;种群太大尽管可以增加优化信息,阻止早熟收敛的发生,但无疑会增加计算量,造成收敛时间太长。根据一般经验,本文将粒子群算法种群规模设置为 100,最大迭代次数设置为 1000 次,以达到全局搜索目的。而对于 ELM,最影响其拟合性能的是隐含层节点数^[15],如果隐含层节点数过多,网络学习时间增多,容易出现过拟合现象。隐含层节点数太少,网络预测误差较大。同时,训练样本的多少^[16]对于拟合能力也有影响。因此,采用试验方法分析确定训练样本数和隐含层节点数。

3.4 测试结果及分析

经过反复试验,训练样本为 22 组(约占总样本的 80%),测试样本为 6 组,隐含层节点数为 15 时模型具有最好的拟合

性能。此时随机选择的训练样本(1~22),测试样本(23~28)以及预测值见表1。对比实测值,训练样本的均方误差值达到了0.18,除个别离群点外,大多数样本相对误差均小于6%,

具有良好的训练精度。测试样本均方误差值为2.56,除第23号样本外,其余样本相对误差小于6%,表明模型具有良好的泛化能力。

表1 训练和测试样本
Table 1 Training and testing samples

序号	总药量/ kg	最大段药量/ kg	距离/ m	高度/ m	质点速度/(mm·s ⁻¹)			误差/ %
					地表面	建筑物实测值	建筑物预测值	
1	56875.00	5600.00	3000	0.76	1.60	1.64	1.61	1.64
2	2137.50	737.50	300	0.61	13.72	14.73	14.63	0.69
3	1350.00	187.50	118	3.05	21.90	55.90	55.74	0.28
4	125.00	41.70	275	1.83	0.65	1.64	1.61	1.77
5	2300.00	50.00	240	7.00	1.49	9.84	9.80	0.39
6	2268.40	200.16	850	3.66	0.25	0.60	0.58	3.50
7	2637.50	250.00	100	4.57	7.61	31.62	30.00	5.12
8	2443.70	125.00	110	1.40	7.01	9.54	9.32	2.30
9	14350.00	1800.00	940	0.92	4.03	5.37	5.15	4.08
10	731.50	300.00	312	2.44	2.00	8.90	8.80	1.09
11	2150.00	445.00	1380	2.44	0.45	0.93	0.91	1.84
12	2029.30	764.40	120	0.76	11.78	14.90	14.59	2.09
13	230.25	118.75	128	2.74	7.75	12.82	12.61	1.62
14	1925.00	175.00	135	3.76	10.36	27.29	27.11	0.66
15	390.00	65.00	350	1.22	0.60	1.19	1.07	10.25
16	1237.50	225.00	400	3.96	4.03	12.53	12.13	3.23
17	712.50	50.00	115	3.66	5.22	7.01	6.79	3.21
18	530.00	80.00	200	3.05	4.18	9.61	9.50	1.13
19	632.75	382.00	325	0.61	2.41	2.48	2.17	12.46
20	1350.00	187.50	130	4.00	15.00	40.10	39.34	1.90
21	775.00	225.00	450	1.20	0.67	1.31	1.11	15.55
22	4520.84	645.00	1190	1.31	0.88	1.98	1.96	0.81
23	1825.00	650.00	200	1.98	9.99	11.33	9.33	17.69
24	260.13	140.70	145	3.20	6.71	14.32	13.52	5.61
25	1475.00	337.50	250	1.52	3.88	10.59	9.99	5.71
26	2300.00	50.00	230	3.05	0.89	3.53	3.33	5.78
27	2443.75	125.00	120	1.78	8.35	21.62	20.47	5.31
28	798.00	114.00	225	3.50	9.91	16.26	15.40	5.32

隐含层节点数对极限学习机有较大的影响,随机选择22组训练样本,在隐含层节点数为10,13,16,19,22,25的情况下用PSO-ELM和ELM训练20次,得到训练样本和测试样本均方误差的平均值随隐含层节点变化,如图3所示。可以看

到,ELM的训练精度和测试精度对隐含层节点数较为敏感,训练精度随着隐含层节点的增加迅速减小,当隐含层节点数等于训练样本数量时,训练精度可达到零误差;测试精度在隐含层节点数较少的情况下较高且较为稳定,而一旦隐含层

节点数接近训练样本数量时,测试样本误差急剧增加,产生了过拟合现象。对于 PSO-ELM 而言,经过粒子群算法优化,训练样本精度比 ELM 有明显提高,而且随隐层节点数变化不大,稳定性好;测试样本精度也比 ELM 模型有所提高,而且在隐层节点数较少时(小于 20),测试误差比较稳定。为使预测误差达到最小,本文将隐含层节点数设置为 15 个。

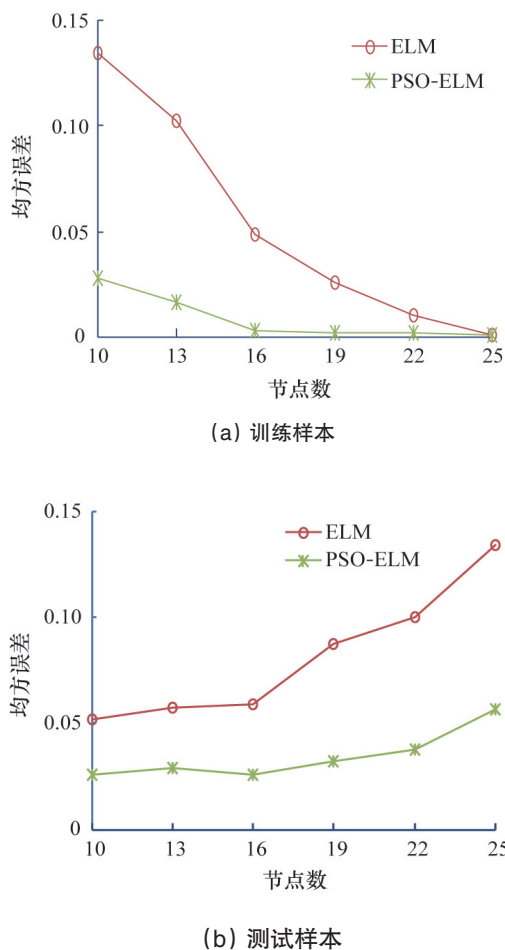


图3 训练样本及测试样本误差随隐含层节点变化
Fig. 3 Training set and testing sets error varies with hidden neurons

为了讨论训练样本数目对 PSO-ELM 模型的影响,将初始训练样本数设置为 16,增加周期为 2 的训练样本数,隐含层节点数为 15 时测试样本的误差如图 4 所示。可以看到,训练样本数对测试精度有影响,在训练样本数小于 22 时,ELM 和 PSO-ELM 模型的测试误差随着训练样本数的增加而减小,但 PSO-ELM 模型的测试误差小于 ELM 的测试误差,训练样本数大于 22 时,ELM 和 PSO-ELM 模型的测试误差都急剧增加。经粒子群算法优化的 ELM 模型降低了对训练样本数的要求,可以在满足同一预测精度条件下,减小训练样本数。




图4 测试样本误差随训练样本数变化
Fig. 4 Testing sets error varies with training sample

4 结论

1) 基于粒子群算法全局搜索最优解原理,建立以总药量、最大段药量、爆破点与监测点距离、建筑物所在地面震动速度和测点到地面的高度为输入变量,以建筑物震动速度为输出变量的爆破震动速度预测的 PSO-ELM 模型,结果表明该模型不但具有良好的训练精度,而且泛化能力良好。

2) 经粒子群算法优化,PSO-ELM 模型与传统 ELM 模型相比有较好的拟合能力,训练精度和泛化能力都明显提高,而且降低了 ELM 模型预测精度对训练样本数和隐含层节点数变化的敏感度,在其他类似工程中有一定的推广价值。

3) 爆破是一个复杂的非线性过程,由本文中实例可以看出,神经网络在处理非线性关系时具有良好的性能。随着非线性理论的不断发展与完善,在爆破震动灾害控制中引入非线性理论将是一个新的研究方向。

参考文献(References)

- [1] 李夕兵. 凿岩爆破工程[M]. 长沙: 中南大学出版社, 2011.
Li Xibing. Drilling and blasting engineering[M]. Changsha: Central South University Press, 2011.
- [2] 钮强. 岩石爆破机理[M]. 沈阳: 东北工学院出版社, 1990.
Niu Qiang. Mechanism of rock blasting[M]. Shenyang: Press of Northeastern Technique Institute, 1990.
- [3] 张守中. 爆炸与冲击动力学[M]. 北京: 兵器工业出版社, 1993.
Zhang Shouzhong. Explosion and shock dynamics[M]. Beijing: Ordnance Industry Publishing House, 1993.
- [4] 杨佑发, 崔波. 爆破震动速度峰值的预测[J]. 振动与冲击, 2009, 28(10): 195-197.
Yang Youfa, Cui Bo. Prediction for vibration intensity due to blasting induced ground motions[J]. Journal of Vibration and Shock, 2009, 28(10): 195-197.
- [5] 张世雄, 杨明亮, 尹家国, 等. 预测爆破波振动强度的经验公式及其在采矿中的应用[J]. 爆破, 2000, 17(3): 3-17.
Zhang Shixiong, Yang Mingliang, Yin Jiaguo, et al. An empirical formula of calculating the vibrating intensity of explosive wave and its application in mining[J]. Blasting, 2000, 17(3): 13-17.

- [6] Hao H, Ma G W, Lu Y. Damage assessment of masonry infilled RC frames subjected to blasting induced ground excitations[J]. Engineering Structures, 2002, 24(6): 799-809.
- [7] 龚声武, 凌同华. 爆破震速预测的模糊神经网络模型及其应用[J]. 矿业研究与开发, 2009, 29(2): 95-97.
Gong Shengwu, Ling Tonghua. Fuzzy neural network model of peak particle vibration velocity forecast for blasting and its application[J]. Mining Research and Development, 2009, 29(2): 95-97.
- [8] 邵晓宁, 徐颖. 岩体爆破振速和损伤预测的支持向量机方法[J]. 采矿与安全工程学报, 2011, 28(3): 384-390.
Shao Xiaoning, Xu Ying. Prediction of vibration velocity and damification during rock blasting based on support vector machine method[J]. Journal of Mining & Safety Engineering, 2011, 28(3): 384-390.
- [9] 潘华贤, 程国建, 蔡磊. 极限学习机与支持向量机在储层渗透率预测中的对比研究[J]. 计算机工程与科学, 2010, 32(2): 131-134.
Pan Huaxian, Cheng Guojian, Cai Lei. Comparison of the extreme learning machine with the support vector machine for reservoir permeability prediction[J]. Computer Engineering & Science, 2010, 32(2): 131-134.
- [10] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and application[J]. Neuro Computing, 2006, 70(1-3): 489-501.
- [11] 刘国海, 张东娟, 梅从立. 基于IRLS-ELM生物发酵在线软测量建模方法[J]. 东南大学学报: 自然科学版, 2011, 41(S1): 10-13.
Liu Guohai, Zhang Dongjuan, Mei Congli. Soft sensor modeling based on improved regularized least-squares extreme learning machine method[J]. Journal of Southeast University: Natural Science Edition, 2011, 41(S1): 10-13.
- [12] 王杰, 毕浩洋. 一种基于粒子群优化的极限学习机[J]. 郑州大学学报: 理学版, 2013, 45(1): 100-104.
Wang Jie, Bi Haoyang. A new extreme learning machine optimized by PSO[J]. Journal of Zhengzhou University: Natural Science Edition, 2013, 45(1): 100-104.
- [13] Kennedy J, Eberhart R. Particle swarm optimization[C]//Proceedings of IEEE International Conference on Neural Networks. Perth, Australia: IEEE 1995: 1942-1948.
- [14] 张红亮, 王水林, 吕颖慧, 等. 爆破震动效应的支持向量机分析预测[J]. 矿业研究与开发, 2007, 27(4): 57-58.
Zhang Hongliang, Wang shuilin, Lü Yinghui, et al. Analysis and forecast of basting vibration effect based on support vector machine[J]. Mining Research and Development, 2007, 27(4): 57-58.
- [15] 雷德明, 严新平. 多目标智能优化算法及其应用[M]. 北京: 科学出版社, 2009.
Lei Deming, Yan Xinping. Multiple objective intelligent optimization algorithms and application[M]. Beijing: Science Press, 2009.
- [16] 范胜波, 王太勇, 汪文津, 等. 样本数量对切削力的神经网络预测精度的影响[J]. 西南交通大学学报, 2005, 40(5): 637-640.
Fan Shengbo, Wang Taiyong, Wang Wenjin, et al. Effect of number of training samples on ANN prediction accuracy for cutting force[J]. Journal of Southwest Jiaotong University, 2005, 40(5): 637-640.

(责任编辑 赵业玲)

·学术动态·



中国科学技术协会

2014年国际工程科技大会召开

2014年6月3日, 国家主席习近平在人民大会堂出席2014年国际工程科技大会并发表题为“让工程科技造福人类、创造未来”的主旨演讲, 指出工程科技是改变世界的重要力量, 发展科学技术是人类应对全球挑战、实现可持续发展的战略选择。习近平强调, 工程科技是人类实现梦想的翅膀, 承载着人类美好生活的向往, 能够让明天充满希望、让未来更加辉煌。希望中外工程科技专家学者加强合作, 共同为人类社会进步作出新的更大贡献。

由联合国教科文组织、国际工程与技术科学院理事会、中国工程院联合举办, 主题为“工程科技与人类未来”的2014年国际工程科技大会2014年6月2日在北京开幕, 来自全球30多个国家的1500多人参加会议。瑞典创新署署长、英国帝国理工学院院长、印度国家工程院院长、英国皇家工程院院长等围绕着工程科技创新、工程与教育、新能源、战略性新兴产业等作学术报告。

国际工程与技术科学院理事会是国际工程科技界最重要的国际组织, 由世界各国的工程院组成, 以促进世界各国通过工程科技进步推动社会经济发展为宗旨。

详见新华网 http://news.xinhuanet.com/2014-06/03/c_11110968875.htm。