

基于GM-RBF神经网络组合模型的水泥强度预测方法

裘国华¹, 申屠南瑛², 施正伦³

1. 中国计量学院信息工程学院, 杭州 310018
2. 中国计量学院机电工程学院, 杭州 310018
3. 浙江大学能源工程学系, 能源清洁利用国家重点实验室, 杭州 310027

摘要 为预测煤矸石代黏土煅烧水泥的28 d抗压强度性能, 根据生产水泥的物检分析数据, 将GM(1,N)预测技术和径向基函数(RBF)神经网络技术相结合, 提出了基于GM-RBF神经网络组合模型水泥强度预测的新方法。该组合模型首先利用试验产品的典型物检数据建立GM(1,N)网络, 对数据进行预处理。然后将输入样本数据进行一次累加生成操作, 并进行归一化, 设置GM-RBF神经网络组合模型预测精度和散步常数。经处理后的输入样本作为RBF神经网络输入向量, 相应的实测28 d抗压强度作为模型的输出期望值开展训练, 比较预测数据与实测数据, 并进行调整, 最终得到符合精度要求的GM-RBF神经网络组合模型。该组合模型一方面避免GM(1,N)模型的理论误差, 利用累加生成运算和样本数据的预处理, 减少了由于训练样本随机性对建模精度产生的影响; 另一方面由于具有自适应、自组织和速度快等特点, 能快速预测水泥远期强度情况。仿真试验表明, 该模型预测精度优于单个GM(1,N)模型或RBF神经网络模型, 具有较好的拟合性, 适用于对水泥强度的预测, 可以为煤矸石代黏土煅烧水泥的质量分析提供有效参考。

关键词 GM-RBF神经网络; 累加生成运算; 抗压强度; 预测模型

中图分类号 TP391.9

文献标志码 A

doi 10.3981/j.issn.1000-7857.2014.03.008

Prediction Method of Cement Strength Based on GM-RBF Neural Network Combination Model

QIU Guohua¹, SHENTU Nanying², SHI Zhenglun³

1. College of Communication Engineering, China Jiliang University, Hangzhou 310018, China
2. College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, China
3. State Key Laboratory of Clean Energy Utilization, Department of Energy Engineering, Zhejiang University, Hangzhou 310027, China

Abstract In order to predict the 28 day compressive strength of coal gangues as clay for cement, a prediction method of grey model and radial basis function (GM-RBF) neural network combination model is presented according to the data of cement physics test analysis. The method makes used of the advantage of both GM and RBF neural network. Firstly, the combination model built up GM(1, N) network based on its test analysis data, and the data were preprocessed. One accumulated generation operation (1-AGO) and normalization were carried out. Predicted precision and scatter constant were set up to the combination model. Then, these processed samples served as the input vectors for RBF neural network, the measurement data of 28 day compressive strength served as output expectation value for model. Comparisons were carried out between prediction data and measurement data, then the data were adjusted logically. Finally, the GM-RBF neural network combination model is fit for precision requirement. AGO and pretreatment were used for data processing which can reduce randomness of training samples. It also shows that the method is self-adaptive, self-organized and fast. The model can not only avoid the theoretical error of GM(1,N), but also predict the further period compressive strength. The results show that it is better than GM(1,N) model or RBF neural network model. The combination model owns a fine agreement and

收稿日期: 2013-09-05; 修回日期: 2013-10-22

基金项目: 国家科技支撑计划项目(2006BAC21B02)

作者简介: 裘国华, 博士, 研究方向为信号与信息处理、资源综合利用, 电子信箱: qghfr@163.com; 施正伦(通信作者), 研究员, 研究方向为资源综合利用, 电子信箱: szl@cmee.zju.edu.cn

引用格式: 裘国华, 申屠南瑛, 施正伦. 基于GM-RBF神经网络组合模型的水泥强度预测方法[J]. 科技导报, 2014, 32(3): 56-61.

adapts to predict cement strength. It can provide efficient reference of quality analysis for coal gangues as clay for cement.

Keywords GM-RBF neural network; accumulated generating operation; compressive strength; prediction model

传统水泥生产属于高耗材、高耗能行业,随着中国对保护黏土资源和环境的日益重视,水泥生产原料的调整势在必行^[1-3]。具有硅铝质和一定热量的煤矸石能否代替黏土生产水泥,需参考的水泥主要指标之一是其28 d抗压强度是否达到国家标准,为尽早获得28 d远期强度信息,提前判断产品质量,提高企业经济效益,有必要进行预测分析。传统预测28 d抗压强度采用线性回归法,将各检测值与水泥强度之间非线性关系简化为线性函数关系,但实际上水泥强度是大时滞、非线性问题,这一方法会引起较大误差^[4]。灰色系统预测模型(grey model, GM)所需样本数据量少、预测方便,对系统未来状态可以做出科学的定量预测,但缺乏自组织、自学习、自适应能力,对非线性问题的预测精度低^[5,6];径向基函数(radial basis function, RBF)神经网络模型具有良好的非线性信息处理能力,可以逼近任何复杂非线性函数,但由于只分析输入和输出,随机性大^[7]。

本文利用灰色预测模型和RBF神经网络模型的优点,提出灰色GM-RBF神经网络组合预测模型。利用灰色预测模型对输入数据的累加生成运算(accumulated generating operation, AGO),减少输入数据的随机性,结合RBF神经网络具有良好的自适应、自学习能力,加快预测收敛速度,提高预测精度。实现对煤矸石代替黏土生产水泥的28 d抗压强度预测分析。

1 预测建模

1.1 灰色预测模型GM(1,N)

灰色预测模型是运用序列算子对无规律的样本数据生成、处理,获得具有规律性的新数据,降低数据随机性,再对得到的新数据进行建模,灰色预测方法采用AGO,并建立微分方程模型,通过求解可以得到预测结果^[5,8]。

GM(1,N)模型作为状态模型,表明N-1个变量对某一个特征变量的一阶导数的作用。其实质是对样本数据进行一次AGO(1-AGO),然后对特征数据序列进行一次紧邻均值生成,通过建立的微分方程,对系统进行预测^[8]。设

$$X^{(0)} = \begin{bmatrix} x_1^{(0)}(1) & x_2^{(0)}(1) & \cdots & x_N^{(0)}(1) \\ x_1^{(0)}(2) & x_2^{(0)}(2) & \cdots & x_N^{(0)}(2) \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{(0)}(n) & x_2^{(0)}(n) & \cdots & x_N^{(0)}(n) \end{bmatrix} \quad (1)$$

为数据序列,其中 $x_i^{(0)}(k)$ 为第*i*个变量的第*k*个分析值,第一列为系统特征数据序列,其余为系统相关因素序列, $x_i^{(0)}$ 为 $x_i^{(0)}$ 的1-AGO序列,即

$$x_i^{(1)}(k) = \sum_{j=1}^k x_i^{(0)}(j), \quad k=1,2,\dots,n; \quad i=1,2,\dots,N \quad (2)$$

$z_1^{(1)}$ 为 $x_1^{(0)}$ 的一次紧邻均值生成序列,即

$$z_1^{(1)}(k) = \frac{1}{2}[x_1^{(0)}(k) + x_1^{(0)}(k-1)], \quad k=2,3,\dots,n \quad (3)$$

建立G(1,N)灰色模型微分方程为

$$x_1^{(0)}(k) + az_1^{(1)}(k) = \sum_{i=2}^N b_i x_i^{(0)}(k) \quad (4)$$

式中, $-a$ 为系统发展系数, $b_i x_i^{(0)}(k)$ 为驱动项, b_i 为驱动系数, $\hat{a} = [a, b_2, b_3, \dots, b_N]^T$ 称为参数列。令

$$B = \begin{bmatrix} -z_1^{(1)}(2) & x_2^{(0)}(2) & \cdots & x_N^{(0)}(2) \\ -z_1^{(1)}(3) & x_2^{(0)}(3) & \cdots & x_N^{(0)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -z_1^{(1)}(n) & x_2^{(0)}(n) & \cdots & x_N^{(0)}(n) \end{bmatrix} \quad (5)$$

$$Y = \begin{bmatrix} x_1^{(0)}(2) \\ x_1^{(0)}(3) \\ \vdots \\ x_1^{(0)}(n) \end{bmatrix} \quad (6)$$

对方程(4)利用最小二乘估计可求得参数列:

$$\hat{a} = (B^T B)^{-1} B^T Y \quad (7)$$

即可得到特征数据序列的模拟值 $\hat{x}_1^{(0)}(k)$,并与实际值进行比较,可得绝对误差 $\varepsilon(k)$ 、相对误差 Δ_k 、平均相对误差MRE和均方根相对误差MSRE,相应计算公式为^[9]

$$\hat{x}_1^{(0)}(k) = -az_1^{(1)}(k) + \sum_{i=2}^N b_i x_i^{(0)}(k) \quad (8)$$

$$\varepsilon(k) = x_1^{(0)}(k) - \hat{x}_1^{(0)}(k) \quad (9)$$

$$\Delta_k = \frac{|x_1^{(0)}(k) - \hat{x}_1^{(0)}(k)|}{x_1^{(0)}(k)} \quad (10)$$

$$MRE = \frac{1}{n} \sum_{k=1}^n \Delta_k \quad (11)$$

$$MSRE = \sqrt{\frac{1}{n} \sum_{k=1}^n (\Delta_k)^2} \quad (12)$$

1.2 RBF神经网络模型

RBF神经网络模型是以函数逼近论为基础的一类前向局部神经网络^[8],结构如图1所示,主要由输入层、隐含层和输出层组成, $X = (x_1, x_2, \dots, x_n)$ 为*n*维输入向量; $R_i(x)$ 为基函数; w_{ik} 是突触权值; $Y = (y_1, y_2, \dots, y_p)$ 为网络输出向量;输入层到隐含层为非线性映射,而隐含层到输出层神经元为线性映射。由于高斯基函数具有表示简单、径向对称和光滑性好等优点,通常基函数选用高斯函数^[10,11]:

$$R_i(x) = \exp\left[-\frac{\|x - c_i\|^2}{2\delta_i^2}\right], \quad i=1,2,\dots,m \quad (13)$$

式中, c_i 为第*i*个基函数的中心; δ_i 为第*i*个感知的变量; $\|x - c_i\|$ 为向量 $(x - c_i)$ 的范数,表示 x 与 c_i 间的距离。

输出层函数为

$$y_k = \sum_{i=1}^m w_{ik} R_i(x), \quad k=1,2,\dots,p \quad (14)$$

式中, p 为输出节点数。




图1 RBF神经网络结构

Fig. 1 Structural diagram of RBF neural networks

1.3 GM-RBF神经网络组合模型

根据上述模型特点,提出两种模型组合利用设想。为与RBF神经网络和GM(1,N)有更好的比较,首先对几个输入变量序列数据 $X^{(0)}$ 和期望输出的数据 $Y^{(0)}$ 进行归一化,然后对归一化的输入数据开展累加生成和再处理,得到的数据作为RBF神经网络的输入数据,而前述得到的归一化输出数据作为期望数据执行训练,训练结果的预测值与实际归一化值进行比较,计算误差,逆向调整RBF神经网络相关参数,直至达到预测精度要求,最后经反归一化得到接近实测的强度值 $Y^{(0)}$ 。GM-RBF神经网络组合模型如图2所示。




图2 GM-RBF神经网络组合模型

Fig. 2 Diagram of GM-RBF neural networks combination model

2 GM-RBF神经网络组合模型预测水泥强度

由于单一预测模型存在的固有不足,采用GM-RBF神经网络组合模型,以实现在少样本信息量情况下达到较高的预测精度。

2.1 模型训练样本选取及预处理

训练样本采用兆山星星集团下属水泥公司利用煤矸石代替黏土生产的水泥,根据该公司两个月每天早晚各测1次的物检分析情况,选取影响水泥28 d强度的8个物检数据为预测模型的输入样本数据^[12]:细度,%;比面积,cm²/kg;CaO,%;SO₃,%;1 d抗折强度(强度1),MPa;3 d抗折强度(强度2),MPa;1 d抗压强度(强度3),MPa;3 d抗压强度(强度4),MPa;把实测28 d抗压强度作为系统特征数据。

接着对异常数据进行判别,对任意

$$\{x_i^{(0)}(k-1), x_i^{(0)}(k), x_i^{(0)}(k+1)\} \subset X_k^{(0)} \begin{cases} i=1, 2, \dots, N \\ k=1, 2, \dots, n \end{cases} \quad (15)$$

如果

$$x_i^{(0)}(k) > \gamma_1 [x_i^{(0)}(k-1) + x_i^{(0)}(k+1)] \quad (16)$$

或

$$x_i^{(0)}(k) < \gamma_2 [x_i^{(0)}(k-1) + x_i^{(0)}(k+1)] \quad (17)$$

式中, γ_1, γ_2 满足 $\gamma_1 > 1, 0 < \gamma_2 < 1$, γ_1, γ_2 视具体问题而定,则称 $x_i^{(0)}(k)$ 为异常数据^[13]。

剔除异常数据后的8个物检检测的数据作为输入样本数据,为便于对灰色GM(1,9)模型、RBF神经网络模型与GM-RBF神经网络组合模型预测进行比较,对于每组输入 $X_i = (x_1, x_2, \dots, x_n)^T, (i=1, 2, \dots, N)$,进行归一化处理,使各数据处在[0,1]之间^[14]:

$$\bar{x}_i = \frac{x_i}{\sqrt{\sum_{i=1}^N x_i^2}} \quad (18)$$

对相应28 d抗压强度数据作为输出数据的归一化为

$$\bar{y}_i = \frac{y_i}{M} \quad (19)$$

式中, M 设为70。

2.2 数据的累加生成及再处理

在预处理基础上,对输入样本数据利用灰色预测的1-AGO技术进行改进,以降低输入数据的随机性,注重总体的发展趋势,使累加后的序列呈现出单增的现象。

$$X_i^{(1)} = \{x_i^{(1)}(k) | i=2, 3, \dots, N; k=1, 2, \dots, n\} \quad (20)$$

其中, $x_i^{(1)}(k)$ 由式(2)得到。

为加快学习训练期间的收敛速度,减少输入数据的运算量,将经1-AGO的数据进行归一化再处理,使训练的数据处于[-1,1]之间,体现水泥物检参数分布的特性,归一化公式为^[13]

$$x_i^{(1)}(k)_{norm} = 2 \times \frac{x_i^{(1)}(k) - x_i^{(1)}(k)_{min}}{x_i^{(1)}(k)_{max} - x_i^{(1)}(k)_{min}} - 1 \quad (21)$$

式中, $x_i^{(1)}(k)_{norm}$ 表示归一化后训练样本数据。

2.3 GM-RBF神经网络组合模型水泥强度预测算法

利用GM-RBF神经网络组合模型对水泥强度的预测算法主要内容有:首先从水泥物检参数中确定样本参量;然后对样本参量进行数据筛选和预处理;接着对作为输入的样本数据进行1-AGO操作和归一化再处理;设置GM-RBF神经网络组合模型和设定网络参数;输入处理后的样本数据;计算结果输出;分析输出层数据是否达到要求,如果没有,则调整权值继续训练;反之,表示训练完成,分析预测误差。

GM-RBF神经网络预测组合模型建模步骤:

1) 选取水泥物检分析正常数据建立GM(1,N)维数为 n 的信息模型,并将样本进行首次归一化。

2) 将输入样本数据进行一次累加生成操作,再次归一化后,设置GM-RBF神经网络组合模型预测精度和散步常数。

3) 以处理后的输入样本作为RBF神经网络输入向量,对应的实测28 d抗压强度作为RBF神经网络模型的输出期望值,对该网络开展训练,其节点数能在训练中自动获取最佳值,以获得相应网络参数。

4) 分析预测数据与实测数据,进行调整,直至得到符合精度要求的模型预测值,从而建立GM-RBF神经网络预测水泥

强度组合模型。

3 仿真试验及结果分析

3.1 仿真试验

样本数据取自煤矸石代黏土生产的水泥所选取的主要物检分析值。首先进行数据判别和预处理,然后选取30组数据进行GM(1,9)模型的1-AGO和归一化,把归一化累加生成的8个参量的数据作为输入样本,28 d抗压强度作为输出样本训练GM-RBF神经网络组合模型。模型采用输入层、隐含层和输出层3层结构^[5],输入层的节点数为8个,隐含层利用高斯径向基函数,输出层则采用线性传递函数。

为对比模型预测情况,分别用GM(1,9)模型和RBF神经网络模型进行比较。RBF神经网络模型的输入向量采用煤矸石代替黏土生产水泥的8个物检数据的归一化序列,GM(1,9)模型和GM-RBF神经网络组合模型数据也以此为基础。

利用Matlab软件对建立的RBF神经网络模型和GM-RBF神经网络组合模型进行仿真分析,两模型的训练误差设为0.001,散步系数为2.7。模型按照设定目标在Matlab软件中进行训练,训练完成后,查看输出误差和拟合情况是否满足训练要求,如预期目标达到,则建模过程结束;否则,调整相应参数,再进行训练,直至满足目标要求为止。

3.2 仿真结果

煤矸石代黏土生产水泥的28 d抗压强度归一化值的GM-RBF神经网络组合模型、RBF神经网络模型的训练误差曲线如图3和图4所示,GM-RBF神经网络组合模型经25次训练后基本达到设计误差要求,而RBF神经网络模型在相同训练次数下的误差是前者的2倍。表明灰色预测中的数据累加生成方式较好地降低了样本输入数据中随机性影响因素,加速模型的训练速度,减少全局误差。

表1为3种模型的部分预测比较情况,表2为它们的误差比较,GM(1,9)模型预测平均相对误差(MRE)为3.92%,RBF神经网络模型预测的MRE则为0.44%,而GM-RBF神经网络组合模型的MRE仅为0.36%;均方根相对误差(MSRE),GM(1,9)模型为4.88%,RBF神经网络模型为0.63%,GM-RBF神经网络组合模型则为0.47%,表明GM-RBF神经网络组合模型误差比GM(1,9)模型、RBF神经网络模型都要小,再次说明GM-RBF神经网络组合模型的AGO有效降低预测误差。

从图5~图7的预测曲线来看,也能观察到GM(1,9)模型预测偏差大,而RBF神经网络模型预测已比较接近期望值,GM-RBF神经网络组合模型的预测数据与实测数据几乎趋于一致,表明GM-RBF神经网络组合模型的预测优于单一的GM(1,9)模型或RBF神经网络模型。




图3 GM-RBF神经网络组合模型训练误差曲线

Fig. 3 Training error curve of GM-RBF neural networks combination model

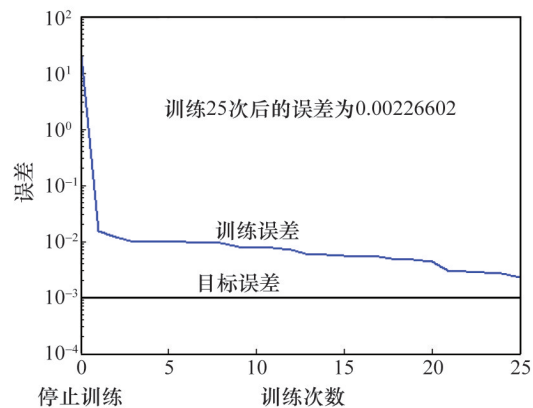


图4 RBF神经网络模型训练误差曲线

Fig. 4 Training error curve of RBF neural networks model

表1 GM(1,9)模型、RBF神经网络模型、GM-RBF神经网络组合模型预测比较

Table 1 Prediction comparison between GM(1,9), RBF neural networks and GM-RBF neural networks combination model

编号	样本期望值	GM(1,9)模型预测值	GM(1,9)模型预测绝对误差	RBF神经网络模型预测值	RBF神经网络模型预测绝对误差	GM-RBF神经网络组合模型预测值	GM-RBF神经网络组合模型预测绝对误差
1	0.8160	0.7735	0.0425	0.8155	0.0005	0.8150	0.0010
2	0.7730	0.7849	-0.0119	0.7825	-0.0095	0.7751	-0.0021
3	0.7800	0.7903	-0.0103	0.7761	0.0039	0.7788	0.0012
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
30	0.8100	0.8352	-0.0252	0.8103	-0.0003	0.8091	0.0009

表2 GM(1,9)模型、RBF神经网络模型、GM-RBF神经网络组合模型误差比较

Table 2 Error comparison between GM(1,9), RBF neural networks and GM-RBF neural networks combination model

误差名称	GM(1,9)模型	RBF神经网络模型	GM-RBF神经网络组合模型
MRE/%	3.92	0.44	0.36
MSRE/%	4.88	0.63	0.47

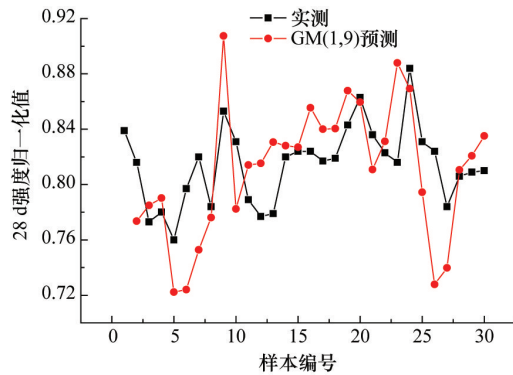


图5 GM(1,9)模型预测曲线

Fig. 5 Prediction curves of GM(1,9) model




图6 RBF神经网络模型预测曲线

Fig. 6 Prediction curves of RBF neural networks model




图7 GM-RBF神经网络组合模型预测曲线

Fig. 7 Prediction curves of GM-RBF neural networks combination model

4 结论

基于煤矸石代黏土生产的水泥物检分析的数据,将GM(1, N)预测技术和RBF神经网络技术相结合,提出了预测水泥28 d抗压强度的改进方法——GM-RBF神经网络组合模型预测方法。该模型一方面避免GM(1, N)模型的理论误差,利用累加生成运算和样本数据的预处理,减少由于训练样本随机性对建模精度的干扰;另一方面由于具有自适应、自组织、速度快的特性,可以快速预测水泥远期强度情况。仿真试验结果表明,预测精度要优于单个GM(1, N)模型或RBF神经网络模型,表明该预测方法具有较好的拟合性,适用于对水泥强度的预测,为煤矸石代黏土煅烧水泥的质量分析提供有益的参考。

参考文献(References)

- [1] Antoni M, Rossen J, Martirena F, et al. Cement substitution by a combination of metakaolin and limestone[J]. Cement and Concrete Research, 2012, 42(12): 1579-1589.
- [2] Choi Y W, Kim Y J, Choi O, et al. Utilization of tailings from tungsten mine waste as a substitution material for cement[J]. Construction and Building Materials, 2009, 23(7): 2481-2486.
- [3] Qiu G H, Luo Z Y, Shi Z L, et al. Utilization of coal gangue and copper tailings as clay for cement clinker calcinations[J]. Journal of Wuhan University of Technology: Materials Science Edition, 2011, 26(6): 1205-1210.
- [4] 李晓东, 杨波, 董吉文. 基于遗传算法的水泥强度预测[J]. 计算机工程与应用, 2004, 40(12): 205-207.
Li Xiaodong, Yang Bo, Dong Jiwen. Predicting of cement strength based on genetic algorithm[J]. Computer English and Applications, 2004, 40(12): 205-207.
- [5] 刘思峰, 党耀国, 方志耕, 等. 灰色系统理论及其应用[M]. 北京: 科学出版社, 2010: 169-171.
Liu Sifeng, Dang Yaoguo, Fang Zhigeng, et al. The theory of grey system and application[M]. Beijing: Science Press, 2010: 169-171.
- [6] 鲍雅萍, 马金元, 宋强. 基于灰色神经网络的烧结矿碱度组合预测[J]. 控制理论与应用, 2008, 25(4): 791-793.
Bao Yaping, Ma Jinyuan, Song Qiang. Combination forecasting of sintered ore alkalinity based on grey neural network[J]. Control Theory & Application, 2008, 25(4): 791-793.
- [7] Alexandridis A, Triantis D, Stavrakas I, et al. A neural network approach for compressive strength prediction in cement-based materials through the study of pressure-stimulated electrical signals[J]. Construction and Building Materials, 2012(30): 294-300.
- [8] 张筠莉, 杨桢山. 现代医院门诊量的灰色RBF神经网络预测[J]. 计算机工程与应用, 2010, 46(29): 225-228.
Zhang Yunli, Yang Zhenshan. Grey RBF neural network based forecasting of outpatient capacity in modern hospital[J]. Computer Engineering and Applications, 2010, 46(29): 225-228.
- [9] 韩涛. 矿渣粉粒度分布特征及其对水泥强度的影响[D]. 西安: 西安建筑科技大学, 2004.
Han Tao. The distribute characteristic of slag powder and the influence on strength of cement[D]. Xi'an: Xi'an University of Architecture and Technology, 2004.

- [10] 景晓璐, 张小栋, 耿加民. 基于RBF神经网络模型和SVM模型的压力传感器温度补偿方法[J]. 科学技术与工程, 2012, 12(26): 6666-6670.
Jing Xiaolu, Zhang Xiaodong, Geng Jiamin. RBF and SVM based temperature compensation algorithms for pressure sensor[J]. Science Technology and Engineering, 2012, 12(26): 6666-6670.
- [11] 闻新, 周露, 王丹力, 等. MATLAB神经网络应用设计[M]. 北京: 科学出版社, 2001: 245-246.
Wen Xin, Zhou Lu, Wang Danli, et al. Application design of neural networks on MATLAB[M]. Beijing: Science Press, 2001: 245-246.
- [12] 郭一军, 段杏林. 基于RBF神经网络水泥强度预测模型的研究[J]. 工业仪表与自动化装置, 2009(2): 99-101.
Guo Yijun, Duan Xinglin. Forecast of cement strength based on RBF neural networks[J]. Industrial Instrumentation & Automation, 2009 (2): 99-101.
- [13] 杨祯山, 邵诚. 基于灰色RBF神经网络模型的电梯层间交通分布预测[J]. 信息与控制, 2008, 37(6): 690-696.
Yang Zhenshan, Shao Cheng. Forecasting of elevator interflow traffic distribution based on grey RBF neural network[J]. Information and Control, 2008, 37(6): 690-696.
- [14] 李晓东. 基于数字图像处理的水泥强度预测模型研究[D]. 济南: 济南大学, 2004: 35-36.
Li Xiaodong. Prediction mode research of cement strength based on digital image processing[D]. Jinan: University of Jinan, 2004: 35-36.
- [15] 杨丹. RBF神经网络预测水泥水化热研究[J]. 国防交通工程与技术, 2011, 9(3): 31-37.
Yang Dan. The prediction of the hydration heat of cement with the RBF neural network[J]. Traffic Engineering and Technology for National Defence, 2011, 9(3): 31-37.

(责任编辑 侯澄芝)

·学术动态·



中国科协“2049年的中国:科技与社会愿景展望” 项目结题评审会召开

2013年12月10日,中国科协调宣部在北京组织召开“2049年的中国:科技与社会愿景展望”项目结题评审会,对“制造技术与未来工厂”、“生物医药技术发展与人类健康”、“城市科学与未来城市”、“生物技术与未来农业”、“可再生能源与节约型社会”、“人工智能与智慧生活”、“预防医学与生命质量”7个课题进行结题评审。中国科协党组成员、书记处书记王春法出席会议并讲话。中国工程院院士赵沁平、中国工程院院士李宁、中国药学会副理事长李少丽、国家自然科学基金委员会研究员雷源忠、北京大学城市与环境学院城市与区域规划系主任吕斌、中国科学院计算技术研究所研究员史忠植等专家出席会议。中国科协调宣部副部长罗晖主持会议。

“2049年的中国:科技与社会展望”项目主要依靠中国科协各学会专家和学者的智慧描绘出一幅幅科技创造未来美好生活的情景,向公众展示新中国成立100周年时的新生活,展望科技给未来生活带来的改变。项目成果主要面向公众、科技工作者和决策者,目标是凝聚社会各界对科技、对未来生活的美好共识,促进社会对科技活动的理解和支持,为决策者应对未来发展提供咨询参考。首批参与项目共7个学会,历时2年研究,项目研究成果最终以研究报告形式展示。

详见中国科协网 <http://www.cast.org.cn/n35081/n35533/n38575/15301104.html>。