

# 煤种成浆性的人工神经网络预测模型研究

李艳昌<sup>1,2</sup> 杨雨濛<sup>1,2</sup> 刘建忠<sup>3</sup>

(1. 辽宁工程技术大学 安全科学与工程学院 辽宁 阜新 123000; 2. 矿山热动力灾害与防治教育部重点实验室 辽宁 葫芦岛 125105;  
3. 浙江大学 能源清洁利用国家重点实验室 热能工程研究所 浙江 杭州 310027)

**摘要:**为更好地预测煤的成浆性,以大量煤种成浆浓度试验数据为基础,建立了3个输出因子的神经网络成浆浓度预测模型。模型采用L-M算法,对输入数据进行数据预处理,最后对比分析了神经网络预测模型与回归分析模型的预测结果。结果表明,以 $A_d$ 、哈氏可磨性指数HGI和氧含量O为输入因子的模型预测结果平均绝对误差为0.63%,以 $M_{ad}$ 、HGI和O为输入因子的模型预测结果平均绝对误差为0.60%,以 $M_{ad}$ 、HGI和氧碳比O/C为输入因子的模型预测结果平均绝对误差为0.40%,3种组合的模型结果均小于回归分析模型的平均绝对误差1.15%。因此神经网络模型比回归分析模型有更好的预测能力,其中以 $M_{ad}$ 、HGI和O/C为输入因子的神经网络模型预测结果最好。

**关键词:**煤;成浆性;神经网络;L-M算法

中图分类号:TQ536 文献标志码:A 文章编号:1006-6772(2016)01-0005-05

## Mathematical model based on artificial neural network for coal slurring prediction

LI Yanchang<sup>1,2</sup>, YANG Yumeng<sup>1,2</sup>, LIU Jianzhong<sup>3</sup>

(1. College of Safety Science and Engineering Liaoning Technical University Fuxin 123000, China; 2. Mine Ventilation and Heat Harm Prevention Laboratory Liaoning Technical University Huludao 125105, China; 3. State Key Laboratory of Clean Energy Utilization Institute for Thermal Power Engineering Zhejiang University Hangzhou 310027, China)

**Abstract:** In order to improve prediction accuracy based on experimental data of coal slurring, BP neural network model with three input factors was set up for slurry concentration prediction. The BP neural networks' algorithm was Levenberg-Marquardt algorithm. The input data was treated in order to get accurate results. The  $A_d$ , HGI, O input factors neural network model's mean absolute errors was 0.63%, the  $M_{ad}$ , HGI, O model's mean absolute error was 0.60% and the  $M_{ad}$ , HGI, O/C model's mean absolute error was 0.40%, but the exist regression model's mean absolute error was 1.15%, so the neural network models were effective in predicting the slurring, and the  $M_{ad}$ , HGI, O/C model was the best among the three prediction models.

**Key words:** coal; slurrability; neural network; Levenberg-Marquardt algorithm

## 0 引 言

水煤浆是由60%~70%煤粉、40%~30%水以及少量添加剂(约0.5%~1%)组成的混合物,是一种低污染、高效率、流动性强的理想代油燃料。发展高温高压高效的大规模气流床水煤浆气化工工艺成为我国洁净煤技术发展的一个重要方向,因此有必要

进一步探讨煤种理化特性和添加剂等对水煤浆成浆性和流变性的影响规律。水煤浆作为一种宽筛分、高固含量的复杂多级分散悬浮体系,煤的种类、化学性质、颗粒度分布及形状、煤粒之间的相互作用、温度和浓度等因素<sup>[1]</sup>都会影响其成浆性和流变性。水煤浆成浆性的研究十分复杂,陈训刚<sup>[2]</sup>、李珊珊<sup>[3]</sup>和王睿坤等<sup>[4]</sup>研究了不同技术手段提高水煤

收稿日期:2015-01-13;责任编辑:白娅娜 DOI: 10.13226/j.issn.1006-6772.2016.01.002

基金项目:国家重点基础研究发展计划(973计划)资助项目(2010CB227001)

作者简介:李艳昌(1976—),男,河北任丘人,副教授,博士,从事水煤浆制备、煤炭自燃等方面的研究。E-mail: liyanchang76@sina.com

引用格式:李艳昌,杨雨濛,刘建忠.煤种成浆性的人工神经网络预测模型研究[J].洁净煤技术,2016,22(1):5-9.

LI Yanchang, YANG Yumeng, LIU Jianzhong. Mathematical model based on artificial neural network for coal slurring prediction[J]. Clean Coal Technology, 2016, 22(1): 5-9.

浆浓度的方法,朱雪丹<sup>[5]</sup>将城市湿污泥以不同比例与煤粉掺混制备污泥水煤浆,研究污泥掺混量、添加剂、温度以及剪切速率对污泥水煤浆成浆特性的影响。煤种理化特性与其成浆性之间存在非线性关系,当煤炭内在水分、灰分、氧碳比、亲水含氧官能团含量越低以及哈氏可磨性指数  $HGI$  越高时,则水煤浆成浆特性越好,而煤阶越低和孔隙越发达的煤种制浆难度越大<sup>[6-8]</sup>。张荣曾教授曾在总结大量煤种成浆浓度试验数据基础上,推荐了一个预测煤炭成浆浓度的三因子回归分析方程<sup>[1]</sup>。笔者基于张荣曾教授对我国 37 种典型煤炭理化特性及其成浆浓度的试验数据,采用人工神经网络建立关于煤炭成浆浓度的非线性预测模型,对不同输入因子组合进行了成浆浓度预测,将预测结果与回归分析模型的预测结果进行对比,分析神经网络预测模型的适用性与准确性。

## 1 网络拓扑关系的建立

人工神经网络技术对实现非线性映射,尤其是解决输入对输出影响的具体机制不太清楚的问题极为有效。由于 3 层反向传播(BP)神经网络在中间层单元根据需要自由设定的情况下,可实现以任意精度近似任何连续函数,故笔者采用 3 层结构的 BP 神经网络<sup>[9]</sup>,建立了预测煤炭成浆浓度的人工神经网络模型,如图 1 所示。

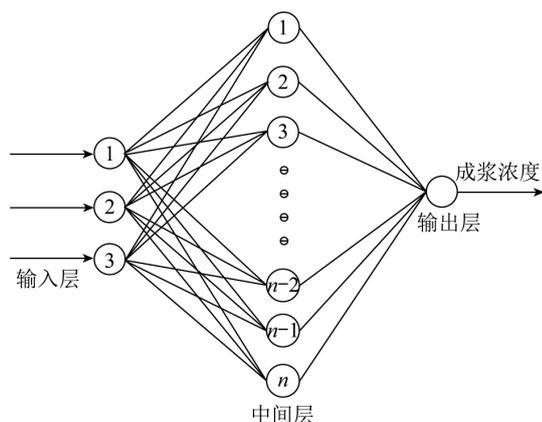


图 1 三因子神经网络预测模型

Fig. 1 Neural network model with three input factors for coal slurring prediction

3 个输入参数为煤炭的理化特性,1 个输出参数为煤炭成浆浓度,中间为隐含层。煤炭理化特性,如  $M_{ad}$ 、 $A_d$ 、 $V_{daf}$ 、 $HGI$ 、 $C_{ad}$ 、 $H_{ad}$ 、 $O_{ad}$ 、 $N_{ad}$  等 8 个参数对其成浆性都有一定影响。但考虑到煤中氢和氮元素含量相对较少,且不同煤种含量差别不大,故建立神

神经网络模型时没有引入氢和氮元素含量作为考查因子,而是另外引入了对成浆性影响较大的氧碳比  $O/C$  作为考查因子。在煤的 7 项理化特性参数中随机抽取 3 项作为考查因子,组合起来作为神经网络模型的 3 项输入数据,比较不同三因子模型关于煤炭成浆浓度的预测精度,最终得到最优的三因子预测模型。

## 2 神经网络算法与参数确定

### 2.1 神经网络的 L-M 算法

本文 BP 神经网络训练所用算法为 L-M 算法(Levenberg-Marquardt 算法)<sup>[10]</sup>,此算法是牛顿法的变形,专门用于误差平方和最小化。BP 神经网络的最速下降算法在进行网络权值  $w$  和阈值  $\theta$  调整时,只是按照当前时刻的负梯度方向进行修正,并没有计及以前的信息,即

$$\Delta w = -a \frac{\partial V}{\partial w} \quad \Delta \theta = -a \frac{\partial V}{\partial \theta} \quad (1)$$

式中  $\Delta w$  为网络权值增量;  $a$  为学习率,  $a > 0$ ;  $\Delta \theta$  为阈值增量。

$$V = \frac{1}{2} \sum_r^P (t_r - y_r)^2 = \frac{1}{2} \sum_r^P e_r^T e_r \quad (2)$$

式中  $V$  为输出层权值;  $P$  为样本总数;  $t_r$  为期望的网络输出向量;  $y_r$  为实际的神经网络输出向量;  $e_r = t_r - y_r$ , 为第  $r$  个输出的误差,  $r = 1, 2, \dots, P$ 。

L-M 算法则是牛顿法的一种近似,如果要求误差指标函数  $V(x)$  的极小值,运用牛顿法则有

$$\Delta x = -[\nabla^2 V(x)]^{-1} \nabla V(x) \quad (3)$$

这里  $\nabla^2 V(x)$  为 Hessian 阵;  $\nabla V(x)$  为梯度,如果假定  $V(x)$  是误差平方和函数

$$V(x) = \sum_{i=1}^N e_i^2(x) \quad (4)$$

式中  $N$  为中间层单元数;  $e_i(x)$  为中间层输出误差。

则有

$$\begin{cases} \nabla V(x) = J^T(x) e(x) \\ \nabla^2 V(x) = J^T(x) J(x) + S(x) \end{cases} \quad (5)$$

这里  $J(x)$  为 Jacobian 矩阵

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_n(x)}{\partial x_1} & \frac{\partial e_n(x)}{\partial x_2} & \dots & \frac{\partial e_n(x)}{\partial x_n} \end{bmatrix}$$

$S(x) = \sum_{r=1}^n e_r(x) \nabla^2 e_r(x)$ , 对于高斯-牛顿法, 则有

$$\Delta x = [J^T(x) J(x)]^{-1} J^T(x) e(x) \quad (6)$$

而 L-M 算法将高斯-牛顿法改进为

$$\Delta x = [J^T(x) J(x) + \mu I]^{-1} J^T(x) e(x) \quad (7)$$

式中  $I$  为单位矩阵;  $\mu$  为自适应因子, 当某一步的计算结果使得  $V(x)$  增加时  $\mu$  乘以修正因子  $\beta$ , 反之则除以  $\beta$ 。当  $\mu$  较大时, L-M 算法近似于最速梯度法, 当  $\mu$  为 0 则为高斯-牛顿法。

## 2.2 数据预处理与神经网络参数设定

本文将样本数据随机分成两部分, 一部分作为训练样本集, 用于训练神经网络; 另一部分作为检验样本集, 不参与神经网络的训练, 用于检验模型的推广能力。根据建立的神经网络模型直接输入未经处理的样本数据时, 虽然可以调整网络的参数, 但即使

经过 30 万步训练, 最小误差仍停留在 2.5122, 无法满足精度要求。鉴于殷春根等<sup>[11]</sup>利用数据预处理方法获得很好效果, 因此本文也对数据进行预处理。

数据预处理方法是利用每个输入或输出向量中的最大值  $Data_{max}$  与最小值  $Data_{min}$ , 通过式(8)将输入向量或输出向量中的每个数值  $Data_i$  变换成  $[-1, 1]$  区间的值  $Data_{new}$ , 形成新的输入向量或输出向量。

$$Data_{new} = \frac{2Data_i - (Data_{min} + Data_{max})}{Data_{max} - Data_{min}} \quad (8)$$

神经网络模型输入层与目标数据的  $Data_{max}$  与  $Data_{min}$  见表 1。

神经网络模型的参数主要是中间层节点数和学习率的设定。根据文献推荐和实际计算经验, 确定该三因子模型的中间层节点数为 20 个, 学习率为 0.01。

表 1 输入数据和目标数据的最大最小值

Table 1 Maximum and minimum of the input and target data

参数	$M_{ad}/\%$	$A_d/\%$	$V_{daf}/\%$	HGI	$w(C_{ad})/\%$	$w(O_{ad})/\%$	O/C 原子比/ $\%$	成浆浓度/ $\%$
$Data_{max}$	17.73	34.75	43.77	120.0	92.61	20.3	28.56	74.90
$Data_{min}$	0.60	2.34	9.10	30.00	61.44	1.83	1.98	52.30

## 3 结果与讨论

不同组合的三因子神经网络模型关于煤炭成浆浓度的预测研究发现, 含有  $V_{daf}$  和碳元素 2 个因子的大多数三因子组合模型的预测结果无法收敛, 少数模型预测结果比较差, 说明  $V_{daf}$  和碳元素 2 个因子与煤炭成浆浓度的关联性很弱。

### 3.1 $A_d$ 、HGI 和 O 的三因子模型

煤炭灰分中存在的某些高价阳离子对于水煤浆的稳定性具有促进作用; 而某些阴离子会降低水煤浆的流变性能, 对成浆性具有阻碍作用<sup>[12]</sup>; 另外一些难溶矿物如黄铁矿、石英和方解石等密度较大, 对水煤浆浓度具有增大作用。由于不同煤种的灰分具有较大差异, 且灰分对煤成浆性的影响比较复杂, 因此将  $A_d$  作为一个影响因子来建立三因子模型, 在预测煤的成浆浓度时会出现某些数据点的预测结果与实际结果相差较大的情况。 $A_d$  作为影响因子的三因子组合模型中, 由  $A_d$ 、HGI 和 O 组成的三因子模型的预测结果最好(图 2), 但在实际煤浆浓度为 65%~70% 时仍存在 2 个偏差很大的数据点。

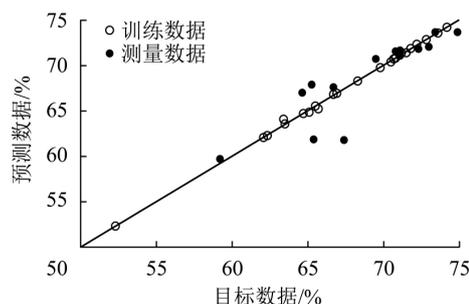


图 2  $A_d$ 、HGI 和 O 的三因子模型预测结果

Fig. 2 Prediction of coal slurring based on neural network model with 3 input factors of  $A_d$ , HGI and O

### 3.2 $M_{ad}$ 、HGI 和 O 的三因子模型

由  $M_{ad}$ 、HGI 和 O 组成的三因子模型关于煤炭成浆浓度的预测结果如图 3 所示。图 3 预测结果明显优于图 2。对于  $M_{ad}$  含量高的煤种, 其颗粒内部的孔隙结构比较发达。利用该煤种制浆时, 由于内部孔隙对水分具有吸附作用, 使水煤浆体系中的自由水分减少, 影响了煤炭的成浆性能, 从而使其在预测过程中相关性更高<sup>[5]</sup>。HGI 与煤中  $M_{ad}$ 、 $A_d$ 、 $V_{daf}$ 、硬度、密度和煤岩类型等<sup>[13]</sup>参数相关, 因此 HGI 集中体现了煤炭的多种理化特性。煤炭氧含量和氧碳比均能反映其氧

含量,对于氧含量高的煤种,其亲水的含氧官能团的绝对含量就高,故其成浆浓度相对较低<sup>[7]</sup>。

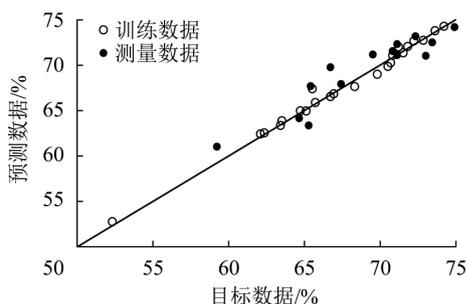


图3  $M_{ad}$ 、HGI和O的三因子模型预测结果

Fig. 3 Prediction of coal slurring based on neural network model with 3 input factors of  $M_{ad}$ , HGI and O

### 3.3 $M_{ad}$ 、HGI和O/C的三因子模型

由 $M_{ad}$ 、HGI和O/C组成的三因子模型的预测结果如图4所示,图4预测模型的结果最好。与图3相比,图4选取O/C因子,同时考虑煤中氧、碳含量,使得三因子神经网络模型的非线性关系更加符合客观规律,能够更加准确预测煤炭的成浆特性。另外,3个神经网络模型中都考虑了HGI,原因可能是HGI综合体现了煤炭的多种理化特性,在三因子模型中能够较好地结合其他因子,从而得到较好的预测结果。考虑O/C的神经网络三因子模型的预测结果最好。

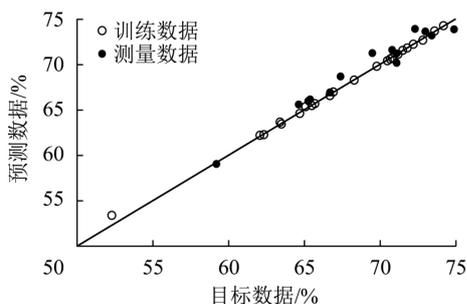


图4  $M_{ad}$ 、HGI和O/C的三因子模型预测结果

Fig. 4 Prediction of coal slurring based on neural network model with 3 input factors of  $M_{ad}$ , HGI and O/C

### 3.4 3种模型与回归分析模型比较

张荣曾教授在总结大量煤种成浆浓度试验数据基础上,推荐了一个预测煤炭成浆浓度的三因子回归分析方程<sup>[1]</sup>,成浆浓度 $S$ (%)可表示为

$$S = 67.848 + 0.061366HGI - 0.267763M_{ad} - 0.030864O^2 \quad (9)$$

利用该回归分析方程对37个典型煤种成浆浓度进行预测,结果如图5所示。对比可知,图2~图

4的三因子神经网络模型的预测结果均明显优于图5中回归分析方程的预测结果。

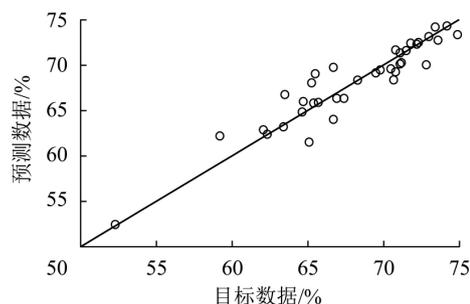


图5 回归分析模型预测结果

Fig. 5 Prediction of coal slurring based on a regression equation

神经网络模型和回归分析模型的平均绝对误差见表2。由表2可知,由 $M_{ad}$ 、HGI和O/C组成的三因子模型的预测结果误差最小,仅为0.40%;由 $M_{ad}$ 、HGI和O组成的三因子模型预测结果误差较小,为0.60%;由 $A_d$ 、HGI和O组成的三因子模型的预测结果误差较大,为0.63%;而回归分析方程的预测结果误差最大,达到1.15%。故本文建立的关于煤炭成浆浓度的神经网络模型比回归分析模型有更好的预测能力,尤其以 $M_{ad}$ 、HGI和O/C的三因子神经网络模型的预测结果最好。

表2 神经网络模型和回归分析模型的平均绝对误差

Table 2 Mean absolute errors of neural network models and a regression equation

项目	神经网络预测模型			回归分析模型
	$M_{ad}$ 、HGI、O/C	$M_{ad}$ 、HGI、O	$A_d$ 、HGI、O	
平均绝对误差/%	0.40	0.60	0.63	1.15

## 4 结 语

根据煤炭的多种理化特性,建立了关于煤炭成浆浓度的多个三因子神经网络预测模型,研究表明 $M_{ad}$ 、HGI、O/C、O和 $A_d$ 等对于煤炭成浆性的预测结果影响显著。神经网络模型对于煤炭成浆浓度的预测结果明显优于传统的回归分析模型,尤其是 $M_{ad}$ 、HGI和O/C的三因子神经网络模型的预测结果最好,其次是 $M_{ad}$ 、HGI和O的三因子模型,二者的平均绝对误差分别为0.40%和0.60%,而现有回归分析方程的误差达到1.15%,说明神经网络模型在煤炭成浆性预测方面具有较大的应用价值。

## 参考文献:

- [1] 张荣曾. 水煤浆制浆技术[M]. 北京: 科学出版社, 1996.
- [2] 陈训刚. 微光波对水煤浆的成浆性和气化性的影响[D]. 杭州: 浙江大学, 2008.
- [3] 李珊珊. 精细水煤浆的颗粒孔隙-成浆及燃烧机理研究[D]. 杭州: 浙江大学, 2006.
- [4] 王睿坤, 刘建忠, 胡亚轩, 等. 水煤浆掺混湿污泥对浆体成浆特性的影响[J]. 煤炭学报, 2010, 35(S1): 199-204.  
Wang Ruikun, Liu Jianzhong, Hu Yaxuan, et al. Influence of wet sludge on the slurring properties of coal-water slurries[J]. Journal of China Coal Society, 2010, 35(S1): 199-204.
- [5] 朱雪丹. 粒度级配对神府煤成浆性能的影响[J]. 洁净煤技术, 2014, 20(4): 1-3.  
Zhu Xuedan. Influence of grading size on slurryability of Shenfu coal[J]. Clean Coal Technology, 2014, 20(4): 1-3.
- [6] Atesok G, Boylu F, Sirkeci A A, et al. The effect of coal properties on the viscosity of coal-water slurries[J]. Fuel, 2002, 81(14): 1855-1858.
- [7] Kaushal K Tiwari, Sibendra K Basu, Kumares C Bit, et al. High-concentration coal-water slurry from Indian coals using newly developed additives[J]. Fuel Processing Technology, 2003, 85(1): 31-42.
- [8] Mishra S K, Senapati P K, Panda D. Rheological behavior of coal-water slurry[J]. Energy Sources, 2002, 24(2): 159-167.
- [9] 杨建刚. 神经网络实用教程[M]. 杭州: 浙江大学出版社, 2001.
- [10] Martin T Hagan, Mohammad B Memhaj. Training feedforward network with the marquardt algorithm[J]. IEEE Transactions on Neural Networks, 1994, 5(6): 989-993.
- [11] 殷春根, 骆仲决, 倪明江, 等. 煤的工业分析至元素分析的BP神经网络预测模型[J]. 燃料化学学报, 1999, 27(5): 408-414.  
Yin Chungeng, Luo Zhongyang, Ni Mingjiang, et al. Relationship between ultimate analysis of any coal and its proximate analysis data[J]. Journal of Fuel Chemistry and Technology, 1999, 27(5): 408-414.
- [12] Li Yongxin, Li Baoqing. Study on the ultrasonic irradiation of coal water slurry[J]. Fuel, 2000, 79(3/4): 235-241.
- [13] 于敦喜, 徐明厚, 刘小伟, 等. 燃煤可磨性指数的人工神经网络预测[J]. 煤炭技术, 2003, 22(9): 91-93.  
Yu Dunxi, Xu Minghou, Liu Xiaowei, et al. Forecast of artificial neural network for burn coal grindability index[J]. Coal Technology, 2003, 22(9): 91-93.
- [6] 张国政, 唐林生, 胡广镇, 等. 氨基磺酸盐高效减水剂概述[J]. 辽宁化工, 2011, 40(4): 408-413.  
Zhang Guozheng, Tang Linsheng, Hu Guangzhen, et al. Summary of amino-sulfonate superplasticizer[J]. Liaoning Chemical Industry, 2011, 40(4): 408-413.
- [7] 李宪军, 郝建英, 王芳芳, 等. 氨基系高效减水剂合成工艺的研究综述[J]. 混凝土, 2010(9): 115-117.  
Li Xianjun, Hao Jianying, Wang Fangfang, et al. Reviews of synthetic technology of amino-based superplasticizer[J]. Concrete, 2010(9): 115-117.
- [8] 赵群, 王新平, 逢鲁峰. 改性氨基磺酸盐高效减水剂的合成研究[J]. 混凝土, 2012(6): 142-144.  
Zhao Qun, Wang Xinping, Pang Lufeng. Modified aminosulfonic-based superplasticizer and synthesizing technology[J]. Concrete, 2012(6): 142-144.
- [9] 孙振平, 蒋正武, 范建东, 等. 氨基磺酸盐高性能减水剂的合成及应用[J]. 硅酸盐学报, 2005, 33(7): 864-870.  
Sun Zhenping, Jiang Zhengwu, Fan Jiandong, et al. Development and application of a sulphonated aminophenol based high performance plasticizer[J]. Journal of the Chinese Ceramic Society, 2005, 33(7): 864-870.
- [10] 颜世涛, 张云飞, 谢慧东, 等. 氨基磺酸盐高效减水剂的合成优化及应用[J]. 广东化工, 2009, 36(12): 69-71.  
Yan Shitao, Zhang Yunfei, Xie Huidong, et al. Research on synthesis and application of aminosulfonic-based superplasticizer[J]. Guangdong Chemical Industry, 2009, 36(12): 69-71.
- [11] 王红霞, 王星, 何廷树. 新型氨基磺酸盐高效减水剂的分子设计及机理研究[J]. 混凝土, 2014(1): 87-89.  
Wang Hongxia, Wang Xing, He Tingshu. Study on the molecular design and mechanism of a new aminosulfonic acid-based superplasticizer[J]. Concrete, 2014(1): 87-89.
- [12] 段清兵. 分级研磨低阶煤高浓度水煤浆制备技术与应用[J]. 煤炭科学技术, 2012, 40(10): 113-115.  
Duan Qingbing. Application of high concentration coal water slurry preparation technology with graded grinding low rank coal[J]. Coal Science and Technology, 2012, 40(10): 113-115.
- [13] GB/T 31426-2015, 气态水煤浆[S].
- [14] 李强, 刘秋明. 无热源法氨基磺酸盐高效减水剂的研制[J]. 新型建筑材料, 2013(8): 78-80.  
Li Qiang, Liu Qiuming. Manufacture of aminosulfonic-based superplasticizer without heat source[J]. New Building Materials, 2013(8): 78-80.
- [15] 张智强, 钱中秋, 丁晓川, 等. 氨基磺酸盐系高性能减水剂的研制[J]. 新型建筑材料, 2006(7): 41-44.  
Zhang Zhiqiang, Qian Zhongqiu, Ding Xiaochuan, et al. Development of high performance aminosulfonic acid-based superplasticizer[J]. New Building Materials, 2006(7): 41-44.
- [16] 李崇智, 冯乃谦, 李永德, 等. 高性能减水剂的研究现状与展望[J]. 混凝土与水泥制品, 2001(2): 3-6.  
Li Chongzhi, Feng Naiqian, Li Yongde, et al. Research and prospect of high performance superplasticizer[J]. China Concrete and Cement Products, 2001(2): 3-6.