

# 基于神经网络的潮湿煤炭气流分级效果预测

郎 军<sup>1,2,3</sup>, 贺琼琼<sup>1,2</sup>, 范徐萌<sup>1,2</sup>, 黄鹏飞<sup>1,2</sup>, 章新喜<sup>1,2</sup>

(1. 中国矿业大学 煤炭加工与高效洁净利用教育部重点实验室, 江苏 徐州 221116; 2. 中国矿业大学 化工学院, 江苏 徐州 221116; 3. 内蒙古伊泰能源有限公司, 内蒙古 鄂尔多斯 017000)

**摘 要:**潮湿煤炭给选煤厂筛分作业带来了极大困难,而气流分级技术可以有效地解决这一问题。在进行潮湿煤炭的分级过程中,通过预先对实际的分级效果能进行预测,进而实现对分级过程进行自动控制。人工智能为分级过程模型的建立提供了新的方法。基于神经网络应用 Python 语言建立了气流分级效果预测模型,以内蒙古伊泰集团煤样为研究样品进行不同条件下 50 组气流分级试验,通过将试验数据随机打乱,选择 45 组数据作为训练集,对机器进行训练学习,5 组作为检测集,选择气流分级试验中初始含水率、有无振动、分级时间 3 个因素作为神经网络的输入,将粗粒级和细粒级 2 个大粒级中的 >6,3~6, <3 mm 粒级的含量作为输出,通过交叉验证的方式,寻找神经网络的最佳参数。训练了 2 个 BP 神经网络 NN1 和 NN2。神经网络 NN1,包含一个隐藏层,隐藏层神经元数量为 6 个,选取的激活函数是 tanh; NN2 神经网络,包含 2 个隐藏层,隐藏层神经元数量分别为 5 和 7 个,选取的激活函数是 identity。NN1 在预测的整体上优于第 2 个神经网络,尤其是粗粒级 3~6, <3 mm 和细粒级 >6,3~6, <3 mm 这 5 个级别预测结果优于第 2 个神经网络,但对于粗粒集 >6 mm 这一级别的预测结果存在较大的偏差。NN2 整体预测结果较为平均,整体偏差不大,对于粗粒级 >6 mm 这一项的预测结果与其他项预测较为接近,明显优于第 1 个神经网络,在整体预测上表现更好,NN2 在 >6 mm 粗粒级预测上优于 NN1。将 2 个网络结合起来,粗粒级 >6 mm 的采用神经网络 NN2 的结果,粗粒级 3~6, <3 mm 和细粒级 >6,3~6, <3 mm 这 5 个预测结果采用 NN1 的预测结果,作为最后的预测结果可提高预测的精度,最后模型的确定系数  $R^2$  为 0.917 8,能对输入数据进行较好的拟合。

**关键词:**潮湿煤炭;气流分级;预测模型;BP 神经网络

中图分类号:TQ530.2 文献标志码:A 文章编号:0253-9993(2021)S2-1001-10

## Prediction of airflow classification effect of wet coal based on BP neural network

LANG Jun<sup>1,2,3</sup>, HE Qiongqiong<sup>1,2</sup>, FAN Xumeng<sup>1,2</sup>, HUANG Pengfei<sup>1,2</sup>, ZHANG Xinxi<sup>1,2</sup>

(1. Key Laboratory of Coal Processing and Efficient Utilization of Ministry of Education, China University of Mining & Technology, Xuzhou 221116, China; 2. School of Chemical Engineering and Technology, China University of Mining and Technology, Xuzhou 221116, China; 3. Inner Mongolia Yitai Group, Ordos 017000, China)

**Abstract:** Wet and sticky raw coal normally results in great difficulties to the deep screening of coal preparation plants. The airflow classification technology can effectively overcome the problem of screen blending. The actual classification

收稿日期:2021-05-28 修回日期:2021-10-29 责任编辑:钱小静 DOI:10.13225/j.cnki.jccs.2021.0904

基金项目:国家重点基础研究发展计划(973 计划)资助项目(2012CB214904)

作者简介:郎 军(1970—),男,内蒙古巴彦淖尔人,博士。E-mail:langjun1577@163.com

通讯作者:章新喜(1964—),男,江苏徐州人,教授,博士。E-mail:zhangxinxi@126.com

引用格式:郎军,贺琼琼,范徐萌,等. 基于神经网络的潮湿煤炭气流分级效果预测[J]. 煤炭学报,2021,46(S2): 1001-1010.

LANG Jun, HE Qiongqiong, FAN Xumeng, et al. Prediction of airflow classification effect of wet coal based on BP neural network[J]. Journal of China Coal Society, 2021, 46(S2): 1001-1010.



移动阅读

effect can be predicted by pre-establishing the mathematical model of the airflow classification process, and then the online control of the airflow classifier can be carried out, which can improve the grading effect of the airflow technology. The paper established an artificial neural networks predictive model of airflow classification effect based on the python language, and selected the coal from Inner Mongolia Yitai Group as research sample. 50 groups of data under different classification conditions were obtained through experiments and 45 groups were randomly selected as training sets, 5 groups as detection sets. Three factors of initial water content, vibration or no vibration, and grading time were selected as the input of the neural network, and the content of particles with size  $>6, 3-6, <3$  mm in the two coarse and fine-grain levels was taken as the output to find the best parameters of the neural network through cross-verification. Two BP artificial neural network NN1 and NN2 were trained. The neural network NN1 included a hidden layer, the neuronal number of hidden layer was 6, and the selected activation function was tanh. The NN2 neural network included two hidden layers, the neuronal numbers of hidden layers were 5 and 7, and the selected activation function was identity. The results show that the NN1 outperforms the second neural network as a whole, especially at the five levels of coarse 3-6 mm,  $<3$  mm and fine-grained  $>6$  mm, 3-6 mm, and  $<3$  mm, but deviates greatly for the coarse-grained  $>6$  mm size. The overall prediction results of the NN2 are relatively average and small overall deviation. The prediction results of coarse-grained  $>6$  mm are similar to other predictions, obviously better than that of the first neural network and better in the overall prediction. The NN1 performs better overall predictions but the NN2 outperforms NN1 in coarse grain set  $>6$  mm prediction. Combining the two networks, the results of NN2 for coarse-grained  $>6$  mm, and the results of NN1 for coarse-grained 3-6 mm,  $<3$  mm and fine-grained  $>6$  mm, 3-6 mm,  $<3$  mm as the final prediction result can improve the accuracy of the prediction, the model's decision coefficient  $R^2$  is set to 0.917 8, which can better fit the input data.

**Key words:** wet coal; classification effect; prediction; BP neural network

随着采煤机械化程度的提高,煤粉量不断增加,加上环保要求洒水除尘,使得井下原煤水分迅速提高<sup>[1]</sup>。这些又湿又黏的原煤给选煤厂分级作业带来极大困难<sup>[2-4]</sup>,而气流分级技术提供了一条有效的湿黏煤炭分级途径<sup>[5]</sup>,在气流分级过程中,希望能够预先对实际的分级效果能进行预测,以提高对生产过程的管理效率,这就需要建立分级过程的数学模型<sup>[6-10]</sup>。分级效果预测模型的建立通常是通过分析原煤在分级过程中的流化脱粉分层特性,建立描述其分级过程的精确数学模型,然后通过对数学模型微分方程的求解,进行分级过程的预测计算<sup>[11-13]</sup>,但这要建立复杂精确的数学模型并求解是非常困难的,因为气流分级过程是一个多干扰、非线性、多变量、时变流程。

神经网络的突出优势在于其具有强大的非线性映射和自适应能力,常用于解决复杂的非线性问题。因此,神经网络的发展为分级过程模型的建立提供了新的方法<sup>[14-16]</sup>。

笔者通过气流分级系统试验先获得大量煤炭分级数据对机器进行训练学习,建立起 BP 神经网络模型,对生产样品的水分及分级机操作条件的变化带来的分级效果变化进行预测,为生产工程和产品质量的控制提供依据。

## 1 煤的气流分级原理及影响因素

气流分级原理如图 1 所示,潮湿煤由入料口进入分级室,落在布风板上,进风口输入的气流经布风板将原料煤吹散,同时将部分细粒煤从大颗粒上吹落,细粒煤随风经由细料出口排出至除尘器收集,粗粒煤由粗颗粒出口排出,从而达到细粒煤分级目的<sup>[17]</sup>。

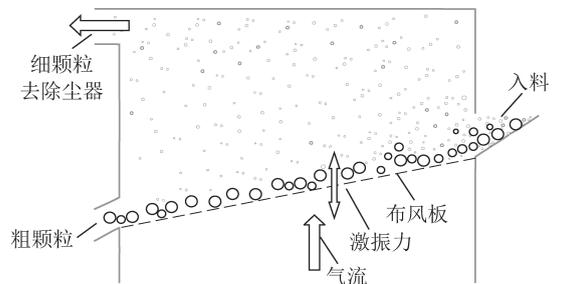


图 1 气流分级原理

Fig.1 Principle of pneumatic classification

一个气流流量对应一个相对固定的分级粒度,在气流流量不变时,分级效果主要受煤样的水分、有无激振力和煤样在分级机内的滞留分级时间(由布风板倾斜角度决定)影响,其分级效果应用粗颗粒产品和细颗粒产品中接近分级粒度的物料含量来评价,本

文中以 6 mm 作为分级粒度。

## 2 BP 神经网络模型

### 2.1 神经网络

人工神经网络的基本单元是人工神经元。在人工神经网络中,信息处理通过人工神经元间的相互作用得以实现,通过权重传递,具有自适应性和连接强度的可变性<sup>[17]</sup>。

人工神经网络通常的结构如图 2 所示。

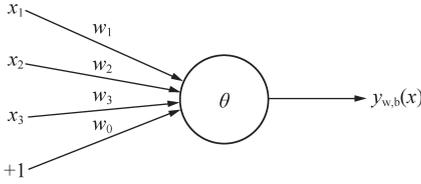


图 2 神经元结构

Fig.2 Neuronal structure

对于某个处理单元(神经元)来说,假设来自其他处理单元(神经元)的信息为  $x_i$ ,它们与本处理单元的互相作用强度即连接权值为  $w_i$ , $i$  的取值为  $0, 1, \dots, n-1$ ,处理单元的内部阈值为  $\theta$ 。

那么本处理单元(神经元)的输入为

$$\sum_{i=0}^{n-1} w_i x_i \quad (1)$$

处理单元(神经元)的输出为

$$y = f\left(\sum_{i=0}^{n-1} w_i x_i - \theta\right) \quad (2)$$

式中, $x_i$ 为样本第  $i$  个特征的输入; $w_i$ 为样本第  $i$  个特征与本处理单元的互联权重,即神经元连接权值; $f$ 为激活函数或作用函数,决定节点(神经元)的输出。

### 2.2 BP 神经网络

BP 神经网络是一种多层前向型网络,由输入层、隐含层以及输出层构成,每一层有  $N$  个神经元<sup>[18-20]</sup>。每一层与层之间通过权值相互连接,同一层的神经元相互无连接<sup>[21-22]</sup>。神经网络首先初始化,随机生成第 1 组权重和偏置,再与输入的数据进行前向传播计算得到一个预测结果<sup>[23]</sup>,再根据实际输出和期望输出之间的误差进行权值的修正,直到网络的输出误差达到预期的结果,就认为网络训练结束<sup>[24-26]</sup>,或进行到预先设定的学习次数为止。神经网络最终的模型计算,就是利用经过最终训练得到的权重和偏置,进行一次前向传播计算,网络的输出取决于网络的结构、网络的连接方式、权重和激活函数<sup>[27]</sup>。

如图 3 所示,这是一个包含 3 层结构的神经网络,由输入层、隐藏层、输出层构成,除了输入层以外,每一层的输入都是上一层的输出。

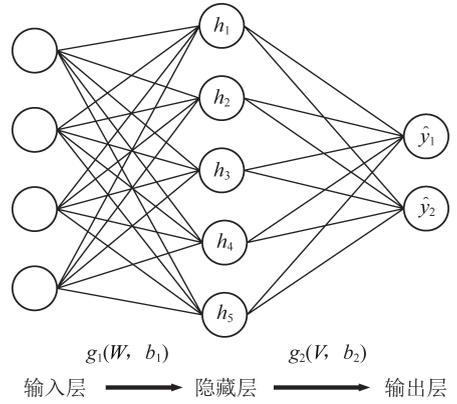


图 3 3 层结构的神经网络

Fig.3 A neural network with a three-layer structure

设输入层到隐藏层的权重值为  $W$ ,偏置项为  $b_1$ ,激活函数为  $g_1$ ,隐藏层到输出层的权重值为  $V$ ,偏置项为  $b_2$ ,激活函数为  $g_2$ ,隐藏层第  $i$  各节点为  $h_i$ ,则图 2 的神经网络模型为

$$\hat{y} = g_2[V^T g_1(W^T X + b_1) + b_2]$$

损失函数(均方误差):

$$E(\theta) = \frac{1}{2} \sum_{i=1}^2 (y_i - \hat{y}_i)^2$$

其中,  $X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix}$ ,

$$W = \begin{pmatrix} w_{11} & w_{12} & \cdots & w_{15} \\ w_{21} & w_{22} & \cdots & w_{25} \\ w_{31} & w_{32} & \cdots & w_{35} \\ w_{41} & w_{42} & \cdots & w_{45} \end{pmatrix}, b_1 = \begin{pmatrix} b_{11} \\ b_{12} \\ \vdots \\ b_{15} \end{pmatrix},$$

$$h = \begin{pmatrix} h_1 \\ h_2 \\ \vdots \\ h_5 \end{pmatrix}, V = \begin{pmatrix} v_{11} & v_{12} \\ v_{21} & v_{22} \\ \vdots & \vdots \\ v_{51} & v_{52} \end{pmatrix}, b_2 = \begin{pmatrix} b_{21} \\ b_{22} \end{pmatrix},$$

$$\hat{y} = \begin{pmatrix} \hat{y}_1 \\ \hat{y}_2 \end{pmatrix}, y = \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}$$

### 2.3 气流分级预测网络模型输入/输出层节点的选择

由前面内容可知,在气流分级试验中不同粒径的含量是不断变化的<sup>[6,28]</sup>,主要考虑初始含水率、有无振动、分级时间这 3 个因素对脱粉特性的影响。一般来说输入层的神经元数目应与所选择的影响因素的变量数目相同<sup>[29]</sup>,因此在本研究中笔者选择了 3 个影响因素作为输入层神经元的数目。而输出层的节点数目与试验的目标参数一致,包括粗粒级和细粒级

2个产品,而每个粒度产品又分别划分为>6,3~6,<3 mm三个精细粒度产品,即选择的输出层节点数为6。笔者基于Python语言建立分级系统的BP神经网络预测模型。

### 3 气流分级预测网络模型相关性评价指标及数据预处理

#### 3.1 气流分级预测网络模型相关性评价指标

在模型相关性检验中,训练样本的决定系数 $R^2$ 以及训练样本均方误差MSE是对模型进行评价的主要方法<sup>[30-31]</sup>。

决定系数 $R^2$ 计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

样本均方误差MSE计算公式:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

式中, $y_i$ 为第*i*个样品的标签真实值; $n$ 为样本的总数目; $\bar{y}_i$ 为第*i*个样品真实值的平均值; $\hat{y}_i$ 为第*i*个样品的预测值。

拟合度取值范围在(0,1),取值越接近于1,表明模型的性能越好;同样,样本均方差越小,表明模型的性能越好。

#### 3.2 试验数据归一化处理

因为试验过程中各个变量的数据范围差异较大,初始含水率、有无振动、分级脱粉时间的取值都不属于同一个数量级,在利用神经网络进行训练的过程中可能会引起数据收敛过慢或根本无法收敛等问题<sup>[32-34]</sup>。数据归一化的目的就是通过对变换将不是同一数量级的数据统一到同一数量级下,这样使得比较起来有意义,能更好地反映数据本身的特征。

数据归一化有两大优点:①归一化可以加快迭代过程中,梯度下降求最优解的速度;②归一化可以提高精度。

常见的数据归一化方法包括min-max标准化,标准差标准化等。

##### 3.2.1 min-max 标准化

通过对原始数据进行线性变换,使变换结果落到 $[0,1]$ ,函数为

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

式中, $x_i$ 为第*i*个样本对应特征取值; $x_{\max}$ 为样本对应特征最大值; $x_{\min}$ 为样本对应特征的最小值; $x_i^*$ 为样本对应特征min-max标准化后的值。

##### 3.2.2 标准差标准化

经过转化的数据符合标准正态分布,即均值为0,标准差为1,量化后的特征将分布在 $[-1,1]$ 。其转化函数为

$$x_i^* = \frac{x_i - \mu}{\sigma}$$

式中, $\mu$ 为样本对应特征的均值; $\sigma$ 为样本对应特征的标准差。

本文在具体模型训练过程中选用了第1种min-max标准化法进行数据归一化处理。

### 3.3 气流分级预测网络模型的训练

基于神经网络结构的气流分级预测网络模型的创建主要涉及几方面的工作,即确定该网络的层数、每层的神经元数目、输出层节点数以及输入层与隐含层、隐含层与输出层之间的传递函数和网络训练函数。

#### 3.3.1 试验数据训练与测试集的划分

通过试验得到不同分级条件下的数据50组,将数据随机打乱,选择45组作为训练集,5组作为检测集,随机划分结果见表1,2。

表1 试验数据训练集合

Table 1 Training set of experimental data

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
3	无	1	36.22	4.93	3.34	4.85	16.57	34.09
3	无	2	35.40	1.17	0.70	5.67	20.33	36.73
3	无	5	31.44	0.38	0.16	9.63	21.12	37.27
3	无	7	30.65	0.53	0.12	10.42	20.97	37.31
6	无	1	36.90	7.85	4.12	4.17	13.65	33.31
6	无	2	35.33	5.90	1.97	5.74	15.60	35.46

续表

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
6	无	3	34.10	4.28	1.01	6.97	17.22	36.42
6	无	5	31.83	1.09	0.53	9.24	20.41	36.90
6	无	7	31.04	0.86	0.45	10.03	20.64	36.98
9	无	1	37.09	7.52	4.55	3.98	13.98	32.88
9	无	2	36.35	5.60	3.84	4.72	15.90	33.59
9	无	3	35.42	4.80	2.45	5.65	16.70	34.98
9	无	5	33.50	2.55	0.95	7.57	18.95	36.48
9	无	7	32.36	0.93	0.65	8.71	20.57	36.78
12	无	1	37.70	8.24	5.35	3.37	13.26	32.08
12	无	2	36.43	7.22	4.76	4.64	14.28	32.67
12	无	3	35.94	6.55	3.52	5.13	14.95	33.91
12	无	5	33.55	4.16	1.72	7.52	17.34	35.71
12	无	7	32.86	1.37	0.97	8.21	20.13	36.46
15	无	1	38.42	9.45	8.33	2.65	12.05	29.10
15	无	2	37.46	8.43	7.01	3.61	13.07	30.42
15	无	3	35.70	7.58	6.36	5.37	13.92	31.07
15	无	5	33.31	4.24	4.58	7.76	17.26	32.85
15	无	7	32.10	3.57	3.10	8.97	17.93	34.33
3	有	1	35.16	4.07	3.03	5.91	17.43	34.40
3	有	2	33.78	1.09	0.63	7.29	20.41	36.80
3	有	5	30.45	0.31	0.13	10.62	21.19	37.30
3	有	7	29.27	0.25	0.10	11.80	21.25	37.33
6	有	1	35.87	6.51	3.78	5.20	14.99	33.65
6	有	2	34.13	4.83	1.82	6.94	16.67	35.61
6	有	3	32.56	3.67	0.88	8.51	17.83	36.55
6	有	5	30.75	0.92	0.40	10.32	20.58	37.03
6	有	7	29.68	0.46	0.26	11.39	21.04	37.17
9	有	2	35.13	4.89	3.13	5.94	16.61	34.30
9	有	3	34.32	3.21	2.10	6.75	18.29	35.33
9	有	7	31.14	0.69	0.52	9.93	20.81	36.91
12	有	2	36.15	6.53	4.55	4.92	14.97	32.88
12	有	3	34.79	4.62	3.17	6.28	16.88	34.26
12	有	5	33.16	2.65	1.36	7.91	18.85	36.07
12	有	7	32.24	1.04	0.78	8.83	20.46	36.65
15	有	1	38.02	10.33	9.15	3.05	11.17	28.28
15	有	2	36.94	9.10	8.32	4.13	12.40	29.11
15	有	3	35.26	8.21	6.75	5.81	13.29	30.68
15	有	5	32.58	5.93	4.62	8.49	15.57	32.81
15	有	7	31.11	4.75	3.01	9.96	16.75	34.42

表2 试验数据测试集合  
Table 2 Test set of experimental data

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
3	无	3	33.62	1.10	0.52	7.45	20.40	36.91
3	有	3	31.64	0.83	0.42	9.43	20.67	37.01
9	有	1	36.77	6.97	4.26	4.30	14.53	33.17
9	有	5	32.91	2.14	0.77	8.16	19.36	36.66
12	有	1	37.43	7.71	5.18	3.64	13.79	32.25

### 3.3.2 神经网络模型预测效果的交叉检验及参数搜索

交叉验证又称为循环估计,是将数据大样本分割成较小子集,以评价机器学习算法对独立于训练数据以外的数据集的预测能力,因此交叉验证可用于验证模型是否过于复杂而引起的过拟合现象。

笔者选用随机45个数据作为训练集,5个数据作为测试集,然后对训练数据分为3个子集,交叉验证重复3次,每次选择一个子集作为验证集,并将3次的平均交叉验证识别正确率作为结果。

参数搜索包括的内容有激活函数的选择和隐含层节点数目的选择。

激活函数包括‘identity’,‘logistic’,‘ReLU’,‘tanh’等。

隐含层节点选取要兼顾2方面的要求,节点选择太少,会使得网络获取的信息太少,网络的学习训练效果不好;节点过多,又会导致网络学习训练时间太久,且不一定能提高精度。常用的选择隐含层节点的经验公式为

$$h = \sqrt{m_{\text{output}} + n_{\text{input}}} + r$$

式中, $h$ 为隐含层节点数; $m_{\text{output}}$ 为输出层节点数; $n_{\text{input}}$ 为输入层节点数; $r$ 为1~10的常数。

根据以上经验公式,隐藏层数及节点数有许多种

$$W(1,1) = \begin{bmatrix} 0.424 & 943 & 43 & -0.512 & 605 & 1 & 0.516 & 319 & 29 & 0.289 & 050 & 74 & -0.104 & 803 & 81 & 0.288 & 305 & 94 \\ -0.037 & 233 & 06 & 0.990 & 447 & 42 & 1.362 & 014 & 21 & 0.219 & 924 & 41 & 0.089 & 037 & 39 & 0.089 & 037 & 39 \\ -0.522 & 019 & 30 & -0.316 & 101 & 65 & 0.162 & 171 & 79 & 0.056 & 559 & 04 & 0.417 & 569 & 59 & 0.133 & 899 & 65 \end{bmatrix}$$

$$W(1,2) = \begin{bmatrix} -1.491 & 186 & 84 & 5.187 & 091 & 73 & 5.396 & 463 & 87 & -3.059 & 831 & 92 & -6.688 & 484 & 80 & 7.248 & 530 & 57 \\ -6.938 & 653 & 99 & -1.992 & 995 & 91 & -0.201 & 208 & 91 & -0.623 & 079 & 33 & -2.374 & 489 & 28 & -6.345 & 690 & 99 \\ 6.595 & 704 & 77 & 0.822 & 385 & 33 & 0.376 & 003 & 57 & 3.654 & 487 & 88 & 3.945 & 545 & 74 & 6.618 & 728 & 39 \\ 5.853 & 959 & 25 & 1.291 & 204 & 46 & 1.107 & 380 & 83 & 1.629 & 112 & 91 & 3.623 & 122 & 05 & 5.805 & 908 & 35 \\ -7.666 & 381 & 10 & -0.814 & 195 & 29 & 1.239 & 318 & 61 & 2.689 & 508 & 61 & -1.212 & 172 & 71 & -5.037 & 327 & 37 \\ 6.370 & 680 & 38 & 0.863 & 842 & 60 & 2.057 & 257 & 53 & 0.883 & 961 & 14 & 3.327 & 849 & 20 & 6.569 & 722 & 62 \end{bmatrix}$$

可能的选择,如单隐藏层[4],[5],[6],[7]……;双隐藏层及节点组合[3,8],[4,4],[5,3],[5,7],[6,3]……。

### 3.3.3 气流分级预测网络模型训练分析及优化

根据前面参数搜索及交叉验证结果,选择较优的2组参数建立气流分级预测网络模型。

第1种神经网络,以下称为NN1(图4),包含1个隐藏层,隐藏层神经元数量为6个,选取的激活函数是tanh。

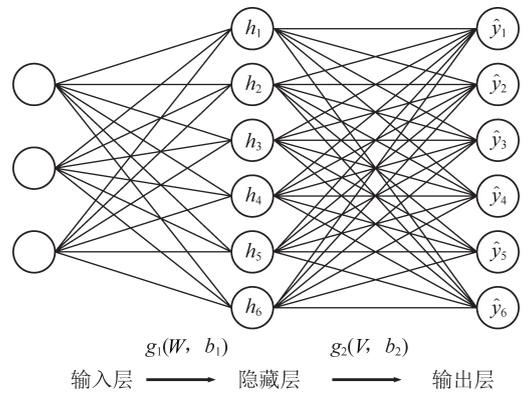


图4 NN1神经网络

Fig.4 Neural network of NN1

NN1神经网络的权重矩阵为

阈值向量为

$$b_1 = \begin{bmatrix} -0.350 & 245 & 00 \\ -3.064 & 100 & 74 \\ 3.155 & 743 & 20 \\ 3.636 & 137 & 14 \\ -0.520 & 266 & 73 \\ 3.311 & 363 & 23 \end{bmatrix} \quad b_2 = \begin{bmatrix} 5.176 & 468 & 94 \\ 0.339 & 157 & 13 \\ 0.980 & 147 & 98 \\ 0.753 & 504 & 81 \\ 2.049 & 520 & 19 \\ 5.777 & 833 & 58 \end{bmatrix}$$

对粗粒级和细粒级 2 个大粒级 >6, 3~6, <3 mm 三个精细粒级决定系数  $R^2$  分别为 0.657 489 46, 0.944 115 45, 0.892 281 34, 0.924 837 09, 0.943 544 30, 0.917 630 63,

平均决定系数  $R^2$  为 0.892 240 16, 均方误差 MSE=0.650 6。NN1 预测结果见表 3。

表 3 神经网络 NN1 预测结果

Table 3 Prediction Result of Neural Network NN1

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
3	无	3	34.47	2.21	0.50	7.32	19.40	36.97
3	有	3	33.61	1.70	0.49	8.47	19.91	36.82
9	有	1	35.63	6.95	5.04	4.80	14.45	32.59
9	有	5	32.97	2.20	1.18	8.94	19.57	36.26
12	有	1	35.78	8.39	6.40	3.95	12.86	31.15

第 2 种神经网络, 以下称为 NN2 (图 5), 包含 2 个隐藏层, 隐藏层神经元个数分别为 5 和 7。

选取的激活函数是 identity, 对粗粒级和细粒级 2 个大粒级的 >6, 3~6, <3 mm 三个精细粒级决定系数  $R^2$  分别为 0.841 483 79, 0.883 321 17, 0.887 346 51, 0.875 399 69, 0.916 247 57, 0.873 810 53。

平均决定系数  $R^2$  为 0.883 786 387 254 718 5, 均方误差 MSE=0.701 6。

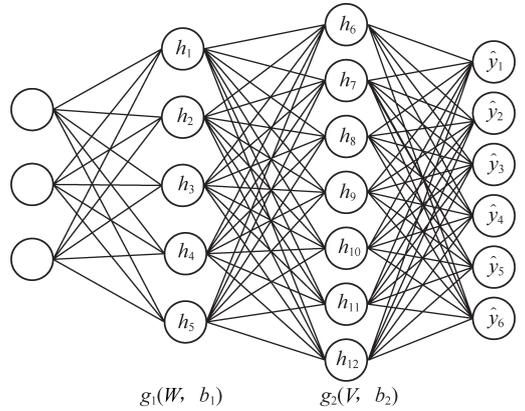


图 5 NN2 神经网络

Fig.5 Neural network of NN2

NN2 权重矩阵为

$$W(1,1) = \begin{bmatrix} -0.731 & 163 & 33 & 0.779 & 668 & 82 & -1.419 & 126 & 58 & -0.911 & 796 & 61 & 0.727 & 306 & 40 \\ -1.048 & 880 & 47 & -0.399 & 895 & 49 & -0.179 & 999 & 85 & 0.095 & 241 & 96 & -0.792 & 392 & 36 \\ 0.085 & 263 & 80 & -0.128 & 507 & 14 & 0.350 & 178 & 43 & 1.549 & 298 & 52 & -2.036 & 561 & 01 \end{bmatrix}$$

$$W(1,2) = \begin{bmatrix} 1.256 & 655 & 49 & 1.317 & 639 & 47 & -0.821 & 616 & 11 & 0.926 & 465 & 26 & 1.265 & 326 & 28 & -0.038 & 344 & 57 & -1.260 & 640 & 69 \\ -1.563 & 613 & 98 & -1.147 & 458 & 22 & 1.056 & 144 & 01 & -1.270 & 802 & 75 & -0.957 & 388 & 76 & 1.246 & 520 & 61 & 0.742 & 527 & 28 \\ -0.402 & 338 & 89 & -0.888 & 051 & 71 & 1.201 & 939 & 55 & -0.127 & 173 & 28 & -1.188 & 387 & 07 & 1.236 & 528 & 25 & 1.371 & 135 & 24 \\ -0.247 & 506 & 61 & -0.970 & 099 & 08 & 1.082 & 760 & 95 & -1.184 & 880 & 75 & -0.642 & 792 & 66 & 1.219 & 922 & 29 & 0.403 & 378 & 21 \\ -1.251 & 485 & 97 & -1.096 & 954 & 86 & -0.241 & 758 & 69 & -0.360 & 558 & 31 & -1.223 & 111 & 44 & 0.167 & 857 & 16 & 0.576 & 276 & 39 \end{bmatrix}$$

$$W(1,3) = \begin{bmatrix} 0.450 & 295 & 58 & -0.584 & 435 & 38 & -1.000 & 672 & 05 & 0.527 & 449 & 12 & 1.082 & 748 & 49 & 0.697 & 048 & 77 \\ 1.149 & 880 & 73 & 0.088 & 629 & 63 & 0.591 & 598 & 25 & -0.162 & 536 & 34 & 0.329 & 601 & 65 & 1.089 & 108 & 22 \\ -0.938 & 156 & 34 & -0.497 & 447 & 02 & 0.417 & 091 & 68 & 0.222 & 590 & 81 & -0.362 & 062 & 19 & -0.330 & 044 & 89 \\ 1.142 & 089 & 40 & 0.225 & 588 & 12 & 0.429 & 412 & 85 & -0.153 & 900 & 78 & 0.429 & 335 & 76 & 1.199 & 997 & 00 \\ 0.457 & 912 & 19 & 0.614 & 938 & 69 & 0.315 & 152 & 74 & 0.516 & 743 & 36 & 0.337 & 796 & 39 & 1.301 & 724 & 33 \\ -0.800 & 979 & 68 & -0.091 & 684 & 45 & -0.349 & 698 & 01 & -0.255 & 973 & 80 & -0.197 & 275 & 02 & -0.534 & 484 & 17 \\ -1.363 & 061 & 63 & 0.299 & 613 & 65 & -0.151 & 028 & 79 & -0.391 & 598 & 49 & -0.433 & 054 & 36 & -0.995 & 726 & 16 \end{bmatrix}$$

阈值向量为

$$b_1 = \begin{pmatrix} 0.969\ 339\ 50 \\ -0.879\ 206\ 82 \\ -0.767\ 353\ 45 \\ -1.396\ 020\ 16 \\ -1.247\ 552\ 57 \end{pmatrix} \quad b_2 = \begin{pmatrix} 0.050\ 449\ 983 \\ 0.643\ 719\ 560 \\ -0.951\ 273\ 690 \\ 0.654\ 800\ 570 \\ 0.876\ 474\ 510 \\ -1.047\ 822\ 820 \\ -0.687\ 553\ 970 \end{pmatrix} \quad b_3 = \begin{pmatrix} 0.946\ 488\ 59 \\ 0.223\ 769\ 47 \\ -0.585\ 913\ 10 \\ 0.824\ 028\ 95 \\ 0.774\ 765\ 70 \\ 1.099\ 884\ 44 \end{pmatrix}$$

神经网络 NN2 的预测结果见表 4。

表 4 神经网络 NN2 预测结果

Table 4 Prediction result of neural network NN2

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
3	无	3	33.99	2.73	0.97	7.13	19.37	36.25
3	有	3	33.05	2.26	0.98	8.07	19.61	36.27
9	有	1	35.93	6.61	4.67	4.92	15.31	32.79
9	有	5	32.41	2.70	1.91	8.77	18.41	35.53
12	有	1	36.48	7.80	5.82	4.30	13.93	31.73

神经网络 NN1 和 NN2 预测结果决定系数  $R^2$  对比见表 5, 可以发现第 1 个网络在预测的整体上优于第 2 个神经网络, 尤其是在粗粒级: 3~6, <3 mm 和细粒级 >6, 3~6, <3 mm 这 5 个预测结果上优于第 2 个神经网络, 但对于粗粒集 >6 mm 这一项的预测结果存在较大的偏差。第 2 个网络整体预测结果较为平均, 整体偏差不大, 对于粗粒级 >6 mm 这一项的预

测结果与其他项预测较为接近, 明显优于第 1 个神经网络。

将 2 个网络结合起来, 粗粒级 >6 mm 的采用神经网络 NN2 的结果, 粗粒级: 3~6, <3 mm 和细粒级 >6, 3~6, <3 mm 这 5 个预测结果采用 NN1 的预测结果, 可提高精度, 最终决定系数  $R^2$  为 0.917 8, 最终预测结果见表 6。

表 5 神经网络 NN1 和 NN2 预测结果决定系数  $R^2$

Table 5 Determinant coefficients  $R^2$  of predictive results of neural networks NN1 and NN2

神经网络	粗颗粒(占全级)/%			细颗粒(占全级)/%			平均 $R^2$
	>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm	
NN1	0.657 5	0.944 1	0.892 3	0.924 8	0.943 5	0.917 6	0.892 20
NN2	0.841 5	0.883 3	0.887 3	0.875 4	0.916 2	0.873 8	0.883 78

表 6 神经网络 NN1 和 NN2 结合预测结果

Table 6 Prediction results of combination of neural network NN1 and NN2

水分/%	振动	分级时间/s	粗颗粒(占全级)/%			细颗粒(占全级)/%		
			>6 mm	3~6 mm	<3 mm	>6 mm	3~6 mm	<3 mm
3	无	3	33.99	2.21	0.50	7.32	19.40	36.97
3	有	3	33.05	1.70	0.49	8.47	19.91	36.82
9	有	1	35.93	6.95	5.04	4.80	14.45	32.59
9	有	5	32.41	2.20	1.18	8.94	19.57	36.26
12	有	1	36.48	8.39	6.40	3.95	12.86	31.15

## 4 结 论

(1) 选择气流分级试验中初始含水率、有无振动、分级时间这 3 个因素作为神经网络的输入, 将粗

粒级和细粒级 2 个大粒级中的 >6, 3~6, <3 mm 粒级的含量分别作为输出, 通过交叉验证的方式, 寻找神经网络的最佳参数。

(2) 训练了 2 个 BP 神经网络 NN1 和 NN2。神

神经网络 NN1, 包含 1 个隐藏层, 隐藏层神经元个数为 6, 选取的激活函数是 tanh; NN2 神经网络, 包含 2 个隐藏层, 隐藏层神经元个数分别为 5 和 7, 选取的激活函数是 identity。

(3) NN1 在整体预测上表现更好, NN2 在粗粒集 >6 mm 预测上优于 NN1, 将 2 个网络结合起来, 作为最后的预测结果可提高预测的精度, 最后模型的决定系数  $R^2$  为 0.917 8, 能对输入数据进行较好的拟合。

### 参考文献 (References):

- [1] FOURIE F, VALICEK P, KRAFFT G, et al. Narrow-reef mechanized mining layout at Anglo American Platinum [J]. Journal of the Southern African Institute of Mining and Metallurgy, 2017, 117(3):263-274.
- [2] VUTHALURU Hari B, ZHANG Dongke. Effect of coal blending on particle agglomeration and defluidisation during spouted-bed combustion of low-rank coals [J]. Fuel Processing Technology, 2001, 70(1):41-51.
- [3] ZHENG Gangfeng, ZHU Jinbo, XIA Wandong, et al. Banana flip-flow screen benefits coal preparation [J]. Filtration Separation, 2016, 53(4):38-41.
- [4] 郎军, 章新喜, 辛学铭, 等. 潮湿动力煤选前深度脱粉试验研究 [J]. 煤炭技术, 2018, 37(12):348-350.  
LANG Jun, ZHANG Xinxi, XIN Xueming, et al. Experimental study on deep depulverization of wet steam coal before separation [J]. Coal Technology, 2018, 37(12):348-350.
- [5] 孟营, 章新喜, 杨啸, 等. 潮湿细粒煤炭复合式气流分级机性能的试验探究 [J]. 矿山机械, 2013, 41(6):80-83.  
MENG Ying, ZHANG Xinxi, YANG Xiao, et al. Experimental investigation on the performance of a composite air classifier for wet fine coal [J]. Mining Machinery, 2013, 41(6):80-83.
- [6] VAN RENSBURG M J. A comparison between high airflow drying and adsorption assisted drying for the dewatering of fine coal [D]. South Africa: Vanderbijlpark North-West University, 2019.
- [7] LI Zhen, FU Yanhong, ZHOU Anning, et al. Air impact pulverization-precise classification process to support ultraclean coal production [J]. Powder Technology, 2017, 318:231-241.
- [8] ZHENG Kehong, DU Changlong, LI Jianping, et al. Coal and gangue underground pneumatic separation effect evaluation influenced by different airflow directions [J]. Advances in Materials Science and Engineering, 2016, 2016:1-13.
- [9] YANG Yong, GE Linhan, HE Yaqun, et al. Mechanism and fine coal beneficiation of a pulsating airflow classifier [J]. International Journal of Coal Preparation and Utilization, 2019, 39(1):20-32.
- [10] 杨啸. 气流分级机自动控制系统的研究 [D]. 徐州: 中国矿业大学, 2014.  
YANG Xiao. Research on the automatic control system of air classifier [D]. Xuzhou: China University of Mining and Technology, 2014.
- [11] LUO Zhenfu, ZHAO Yuemin, YU Xiaodong, et al. Effects of characteristics of clapboard unit on separation of <6 mm fine coal in a compound dry separator [J]. Powder Technology, 2017, 321:232-241.
- [12] ZHOU Enhui, FAN Xuchen, DONG Liang, et al. Process optimization for arsenic removal of fine coal in vibrated dense medium fluidized bed [J]. Fuel, 2018, 212:566-575.
- [13] ZHANG Guilin, SONG Shulei, YANG Weiqiao, et al. Occurrence characteristics of mercury in high-mercury coal and distribution rule of mercury in products of an air dense medium fluidized bed [J]. International Journal of Mining Science and Technology, 2018, 28(6):1015-1020.
- [14] 刘军霞, 阳春华, 王雅琳. 螺旋分级过程数学模型研究及应用 [J]. 计算机工程与应用, 2010, 46(4):230-232.  
LIU Junxia, YANG Chunhua, WANG Yalin. Research and application for spiral classification process mathematic model [J]. Computer Engineering and Applications, 2010, 46(4):230-232.
- [15] 沈恺乐, 李宗强. 基于 BP 神经网络的臭氧精确投加控制系统 [J]. 净水技术, 2021, 40(4):78-84.  
SHEN K Y, LI Z Q. Accurate ozone dosage control system based on BP neural network [J]. Water Purification Technology, 2021, 40(4):78-84.
- [16] 谢翠雪. 神经网络算法在铁矿石研磨节能的研究 [D]. 唐山: 河北联合大学, 2014.  
XIE Cuixue. Research of Neural Network algorithm in the iron ore grinding for energy-saving. [D]. Tangshan: Hebei United University, 2014.
- [17] 陈峰, 章新喜, 梅雄, 等. 潮湿细粒煤炭的气流分级试验研究 [J]. 煤炭工程, 2012(3):90-92.  
CHEN Feng, ZHANG Xinxi, MEI Xiong et al. Study on airflow grading experiment of wet and fine particle coal [J]. Coal Engineering, 2012(3):90-92.
- [18] WANG Baowei, GU Xiaodu, MA Li, et al. Temperature error correction based on BP neural network in meteorological wireless sensor network [J]. International Journal of Sensor Networks, 2017, 23(4):265-278.
- [19] WANG Shouxiang, ZHANG Na, WU Lei, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method [J]. Renewable Energy, 2016, 94:629-636.
- [20] LI Jichao, ZHAO Danling, GE Bingfeng, et al. A link prediction method for heterogeneous networks based on BP neural network [J]. Physica A: Statistical Mechanics and its Applications, 2018, 495:1-17.
- [21] WANG Deyun, LUO Hongyuan, GRUNDER Olivier, et al. Multi-step ahead electricity price forecasting using a hybrid model based on two-layer decomposition technique and BP neural network optimized by firefly algorithm [J]. Applied Energy, 2017, 190:390-407.
- [22] ZHANG Yagang, CHEN Bing, ZHAO Yuan, et al. Wind speed prediction of IPSO-BP neural network based on Lorenz disturbance [J]. IEEE Access, 2018, 6:53168-53179.
- [23] HE Fei, ZHANG Lingying. Prediction model of end-point phosphorus content in BOF steelmaking process based on PCA and BP neural network [J]. Journal of Process Control, 2018, 66:51-58.

- [24] CHENG Jun, WANG Xin, SI Tingting, et al. Maximum burning rate and fixed carbon burnout efficiency of power coal blends predicted with back-propagation neural network models [J]. *Fuel*, 2016, 172:170-177.
- [25] ZHANG Sirui, WANG Botao, LI Xueen, et al. Research and application of improved gas concentration prediction model based on grey theory and BP neural network in digital mine [J]. *Procedia CIRP*, 2016, 56:471-475.
- [26] YANG Yuexiang, ZHENG Xiaoyu, SUN Zhen. Coal resource security assessment in China: A study using entropy-weight-based TOPSIS and BP neural network [J]. *Sustainability*, 2020, 12(6):2294.
- [27] MA Dongliang, ZHOU Tao, CHEN Jie, et al. Supercritical water heat transfer coefficient prediction analysis based on BP neural network [J]. *Nuclear Engineering and Design*, 2017, 320:400-408.
- [28] NOOR NAW Mohd, HASSAN H, HASHIM M F, et al. Preliminary investigation on the effects of primary airflow to coal particle distribution in coal-fired boilers [A]. *Journal of Physics: Conference Series* [C]. IOP Publishing Ltd., 2017:012033.
- [29] 谢健. 基于人工神经网络的落叶松木材干燥模型研究 [D]. 哈尔滨:东北林业大学, 2013.
- XIE Jian. Research on larch wood drying model based on artificial neural network [D]. Harbin: Northeast Forestry University, 2013.
- [30] TALAAT Mohamed, GOBRAN MH, WASFI M. A hybrid model of an artificial neural network with thermodynamic model for system diagnosis of electrical power plant gas turbine [J]. *Engineering Applications of Artificial Intelligence*, 2018, 68:222-235.
- [31] WANG Fang, MA Suxia, WANG He, et al. Prediction of NO<sub>x</sub> emission for coal-fired boilers based on deep belief network [J]. *Control Engineering Practice*, 2018, 80:26-35.
- [32] SACCENTI Edoardo. Correlation patterns in experimental data are affected by normalization procedures: consequences for data analysis and network inference [J]. *Journal of Proteome Research*, 2017, 16(2):619-634.
- [33] SHEN Xiaotao, GONG Xiaoyun, CAI Yuping, et al. Normalization and integration of large-scale metabolomics data using support vector regression [J]. *Metabolomics*, 2016, 12(5):89.
- [34] 李英伟. 基于增量改进 BP 神经网络微波深度干燥模型及应用研究 [D]. 昆明:昆明理工大学, 2011.
- LI Yingwei. Research on microwave deep drying model and application based on incrementally improved BP neural network [D]. Kunming: Kunming University of Science and Technology, 2011.