

1-3-2019

Prediction Model of Coke Quality Based on DE-BP Neural Network

Wenhua Tao

School of Information and Control Engineering, Liaoning Shihua University, Fushun 113001, China;

Zhengbo Yuan

School of Information and Control Engineering, Liaoning Shihua University, Fushun 113001, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Prediction Model of Coke Quality Based on DE-BP Neural Network

Abstract

Abstract: The quality of coke has a great effect on the furnace process. In order to solve the problem of large amount of calculation and inspection of coke quality prediction linear method, *the coke quality prediction model based on DE-BP neural network is established on the basis of analyzing the factors affecting coke quality, which uses principal component analysis method to determine the parameters of the input vector with the coal and coke ash quality indicators A_d , sulfur S_{td} , crushing strength M_{40} , abrasion resistance M_{10} as the output vector prediction.* The result of simulation shows that the relative errors of real and estimated values of the indicators are below 4%, overcoming the low prediction precision of BP neural network and the shortcoming of easily trapped in local minimum. It can meet the requirements of production process and has a certain value for coke production.

Keywords

BP neural network, coke quality, differential evolution algorithm, predictive model

Recommended Citation

Tao Wenhua, Yuan Zhengbo. Prediction Model of Coke Quality Based on DE-BP Neural Network[J]. Journal of System Simulation, 2018, 30(5): 1650-1656.

焦炭质量的 DE-BP 神经网络预测模型研究

陶文华, 袁正波

(辽宁石油化工大学信息与控制工程学院, 辽宁 抚顺 113001)

摘要: 焦炭的质量对高炉冶炼的生产有着重要的影响, 为解决焦炭质量预测线性方法计算量大、检验难问题, 在分析焦炭质量影响因素基础上, 采用主元分析的方法确定配合煤参数的输入向量, 以焦炭质量指标中灰分 A_d 、硫分 S_{td} 、抗碎强度 M_{40} 、耐磨强度 M_{10} 作为输出向量, 建立了焦炭质量的 DE 优化 BP 神经网络预测模型。预测效果表明该模型焦炭质量各项指标的预测值与真实值的相对误差均在 4% 以下, 克服了 BP 神经网络预测精度低、易陷入局部极小值的缺点, 可以满足生产工艺的要求, 对焦炭生产具有一定的使用价值。

关键词: BP 神经网络; 焦炭质量; 差分算法; 预测模型

中图分类号: TP183

文献标识码: A

文章编号: 1004-731X (2018) 05-1650-07

DOI: 10.16182/j.issn1004731x.joss.201805004

Prediction Model of Coke Quality Based on DE-BP Neural Network

Tao Wenhua, Yuan Zhengbo

(School of Information and Control Engineering, Liaoning Shihua University, Fushun 113001, China)

Abstract: The quality of coke has a great effect on the furnace process. In order to solve the problem of large amount of calculation and inspection of coke quality prediction linear method, the coke quality prediction model based on DE-BP neural network is established on the basis of analyzing the factors affecting coke quality, which uses principal component analysis method to determine the parameters of the input vector with the coal and coke ash quality indicators A_d , sulfur S_{td} , crushing strength M_{40} , abrasion resistance M_{10} as the output vector prediction. The result of simulation shows that the relative errors of real and estimated values of the indicators are below 4%, overcoming the low prediction precision of BP neural network and the shortcoming of easily trapped in local minimum. It can meet the requirements of production process and has a certain value for coke production.


Keywords: BP neural network ; coke quality; differential evolution algorithm; predictive model

引言

高炉炼铁过程中焦炭不仅是供热燃料与增碳剂, 而且起着还原剂与支撑骨架的作用^[1]。由于高

炉生产率的提高与焦比的降低, 对预测焦炭质量各项指标灰分、硫分、机械强度、冷热态性质等就尤为重要^[2-3]。

焦炭是一个多变量、非线性等复杂问题的大工业生产过程, 目前国内外研究学者对预测焦炭质量基本采用线性回归和神经网络的方法。文献[4-5]在分析线性方法的基础上, 依据在配合煤转变成焦炭的过程中, 配合煤与焦炭中的灰分、硫分呈现出良好的线性关系建立了预测模型, 回归系数采用最



收稿日期: 2016-06-03 修回日期: 2016-08-03;
基金项目: 国家自然科学基金面上基金(61473140), 国家自然科学基金青年基金(61203021);
作者简介: 陶文华(1972-), 女, 辽宁, 硕士, 教授, 研究方向为系统建模、智能控制等; 袁正波(1990-), 男, 山东, 硕士生, 研究方向为过程控制与优化。

<http://www.china-simulation.com>

• 1650 •

小二乘法来确定。文献[6]对其预测模型增加了线性加权修正, 建立了 M_{40} 、 M_{10} 、 CRI 与 CSR 的配合煤性质预测模型。但线性回归预测方法忽略了小样本非线性因果关系, 系数往往人为因素较多、计算量大, 有很大的局限性。文献[7]对配煤中焦炭质量指标影响的各种因素及传统预测焦炭质量的方法进行了分析, 采用 BP 神经网络建立预测模型。文献[8]建立了 RBF 神经网络与 PCA 相结合的模式, 解决了焦炭质量测量严重滞后的问题。但神经网络具有依赖样本性强、不具备全局搜索能力、易陷入局部极值、学习速率慢、连接权值和阈值是随机产生等问题^[9]。为了解决上述问题, 本文将差分算法运用到 BP 网络优化中, 采用差分算法的优选能力来改善 BP 神经网络连接权值与阈值随机产生的问题。最后验证了基于 DE-BP 优化的预测模型的可行性, 并对比分析其预测精度。

1 焦炭质量预测模型变量的确定

配煤工艺和配合煤的性质是影响焦炭质量两大重要因素, 在现有的炼制焦炭行业中配煤工艺已经相当成熟, 深入研究意义不大。若想提高焦炭的质量只能采用提高配合煤的质量这种方式, 为了保证焦炭的质量, 就应该了解配合煤的各项指标在炼焦过程中所起的作用^[10-11]。

(1) 配合煤灰分

焦炭中的灰分含量过高会使焦炭的质量严重下降, 造成焦炭的机械性能(M_{40} 、 M_{10})无法达到钢铁行业的标准。由于灰分是一种特殊的惰性物质, 会使得炼焦煤料的细度达不到要求, 造成焦炭中心生成较大的裂纹。通过实践检验及分析, 配合煤灰分的含量一般控制在 9%~11%之内。

(2) 配合煤硫分

硫化物对于焦炭来说是一种有害的杂质, 在钢铁的生产过程中这些杂质会随着焦炭进入到生铁中。硫分不但降低了焦炭的机械强度而且对于钢铁的生产也是有害物质, 当硫分过多时会使得生铁具有热脆性, 而且焦炭中的硫分在生产过程中其生成的

氧化物会对钢铁具有腐蚀作用。因此, 配合煤中硫分的含量不应超过 1.2%, 且硫分越低越好。

(3) 配合煤水分

配合煤中的水分主要对炉体的寿命以及焦炭的产量产生重大影响。焦炭的结焦时间会随着配合煤中水分的增加而增加, 在同等条件下, 由于炼焦时间的增加, 就会导致焦炭产量的降低。对于炼焦炉体来讲, 若是配合煤中水分的含量波动较大, 就会使炉体中立火道的温度难以保持稳定而且难以实施控制, 对炉体造成损害。当配合煤中的水分含量较低时, 不但可以提高焦炭的机械强度, 还可以提高焦炭的产量, 在焦炭的生产中, 配合煤的水分含量一般控制在 1%左右。

(4) 配合煤挥发分

挥发分是影响焦炭质量的重要因素, 评价焦炭是否成熟取决于挥发分含量的多少。当挥发分的含量在配合煤中过高时, 会影响焦炭反应特性及其机械特性。当挥发分的含量在配合煤过低时, 不但焦炭的耐磨强度会降低而且会导致炉体的损坏。配合煤挥发分的含量一般控制在 28%~32%之间。

(5) 配合煤粘结指标

配合煤的粘结性好, 这时胶质体的数量就会相对比较多, 具有良好的结焦性, 提高了焦炭的耐磨强度。当粘结性较差时, 就会降低焦炭的抗碎强度和耐磨强度。为了保证达到工业标准, 配合煤的粘结性指数的范围一般是在 50~85 之间。

(6) 配合煤磷分

磷分在焦炭中的含量很少, 主要来源于炼焦煤料, 焦炭中磷分几乎全部是由煤中的磷分转入, 含量要低于生产工艺要求的 0.05%, 过高钢铁具有热脆性。

(7) 配合煤细度

配合煤中一定细度的煤粉可以改善焦炭耐磨强度、抗碎强度以及焦炭的热性能。结合炼焦工艺细度以控制在 76%左右为宜。

通过我们对其影响因素分析可知, 配合煤包含的指标较多, 本文采用主元分析(PCA)的方法进行

处理,主元分析是一种采用降维的统计方法,该方法能够抓住所研究问题的主要矛盾,并把多个变量化为少数几个主成分。在一个低维空间来快速处理数据并保留对数据集方差贡献最大的特征。提取影响焦炭质量的主成分,这几个主成分能够反映原始变量的主要信息并且各主成分之间互不相关,解决了焦炭质量预测模型输入变量过多的问题,降低了建模难度。保证各项配合煤指标符合标准,为更高的预测精度提供根据,本文预测模型的输入变量为提取的各项配合煤的指标,焦炭质量指标根据冶金焦炭技术指标要求作为输出变量。

2 焦炭质量预测模型的建立

2.1 BP神经网络预测模型

通过对焦炭质量影响变量的分析,最终得到配合煤提取的主成分 x_1 、 x_2 、 x_3 、 x_4 、 x_5 确定为输入变量。焦炭质量衡量指标:灰分 A_d 、硫分 S_{td} 、抗碎强度 M_{40} 以及耐磨强度 M_{10} , 将这四个指标作为输出变量。

根据 Hecht-Nielsen 的证明结论采用三层网络结构即可满足要求。以 kolmogorov 定理进行多次训练并比较每次获得的目标误差,隐含层节点数目确定为 12 个。采用 Sigmoid 函数为网络模型的转移函数,该函数可以将神经元的输入范围从 $(-\infty, +\infty)$ 映射到 $(-1, +1)$, 并且可以处理和逼近输入和输出的非线性关系。建立如图 1 所示的 BP 神经网络焦炭质量模型。




图 1 BP神经网络焦炭质量模型

Fig. 1 BP neural network model coke quality

2.2 差分算法

差分算法是由 Rainer Storn 和 Kenneth Price 在 1995 年提出的一种基于种群差异的进化算法。DE 算法的基本思想是首先将 A 个体与 B 个体求差并加权, 然后与 C 个体相加来产生新个体 D, 最后将 D 与同代种群中某个预置个体相比较, 选取适应度值更高的个体作为子代。算法本身容易理解、结构简单, 可以用于求解高维函数问题, 在优化非线性函数具有较强的稳健性, 现如今差分算法已成功应用于多个领域^[12-13]。

DE 算法是一种用于优化问题的启发式算法, 在解的取值范围内生成一个随机的初始种群, 然后通过差分变异、交叉、选择操作, 产生新一代种群。其变异方式有效利用群体分布特性, 提高算法的搜索能力, 避免遗传算法中变异方式的不足^[14-15]。它首先生成随机初始化种群: $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$, 其中 $i=1,2,\dots,N$, D 为问题的维数, N 为种群大小。

(1) 变异操作(Mutation)

DE 算法在每一代搜索中通过变异操作作为当前种群中的个体 $x_i(g)$ 生成一个目标个体 $t_i(g)$, 其中 g 代表进化代数。基本原理是将一个差分向量加到一基向量上去。在这个过程当中, 根据差分向量的计算方式和个数, 以及基向量的选择方式, 变异方式为 DE/rand/1, 方程式如下:

$$v_i(g) = x_{r_1}(g) + F \times [x_{r_2}(g) - x_{r_3}(g)] \quad (1)$$

其中, $r_1, r_2, r_3 \in (1, 2, 3 \dots N)$ 为不等于 i 的互不相同的整数, F 为缩放因子, 通常 F 的取值在 0~2。

(2) 交叉操作(Crossover)

交叉操作的引入是为了增加种群的多样性。为了使优良个体得以保留, 当前个体 x_i 的部分代码和目标个体 t_i 的对应代码相互交换一些元素, 生成新个体 u_i 。通过随机选择, 使试验向量至少有一个分量由变异向量提供, 本文采用二项式交叉操作方程:

$$u_{i,j}(g) = \begin{cases} v_{i,j}(g) & \text{randb}(0,1) \leq CR \text{ 或者 } j = j_{\text{rand}} \\ x_{i,j}(g) & \text{otherwise} \end{cases} \quad (2)$$

式中: $j=1, 2, \dots, D$, 为 $[1, D]$ 随机选择的整数,

$CR \in (0,1)$ 为交叉率。

(3) 选择操作(Selection)

整个种群的进化方向取决于选择操作。差分算法产生后代群体之后, 将父个体与子个体进行相应的一对一贪婪选择策略, 保存较优者到下一代, 择操作如公式(3)所示。

$$x_{i,j}(g+1) = \begin{cases} u_i(g) & f(u_i(g)) \leq f(x_{i,j}(g)) \\ x_{i,j}(g) & \text{otherwise} \end{cases} \quad (3)$$

式中: $x_{i,j}(g+1)$ 代表的是下一代的的目标向量。

2.3 差分算法优化 BP 神经网络

本文差分算法优化 BP 神经网络就是利用了 DE 算法对复杂函数的优化能力, 运用差分算法对网络连接权值与阈值进行训练。种群中每一个个体的参数变量都有 BP 神经网络的各连接权值和阈值构成, 对该种群个体的评价采用适应度函数指标, 然后在通过差分算法对种群空间中的个体寻优, 当 BP 神经网络的输出达到目标误差则停止训练。具体步骤如下:

Step 1: 初始化参数的设置。 BP 神经网络初始化: BP 神经网络的层数, 每层神经元节点数目、传递函数、训练次数和训练目标。DE 算法相关参数初始化: 初始化种群的最大进化次数 t_{\max} 、种群规模 N 、缩放因子 F 、交叉概率 CR 。

Step 2: 权值和阈值的初始化。

Step 3: 初始种群的适应度值: 运用焦炭质量预测模型产生的数据对模型进行训练, 将过程中产生的均方误差的平均值作为适应度值。

Step 4: 变异操作: 运用公式(1)进行变异操作。

Step 5: 交叉操作: 运用公式(2)进行变异操作。

Step 6: 选择操作: 运用公式(3)进行变异操作。

Step 7: 新个体适应度值: 更新种群的适应度值是在经过 DE 算法的三个步骤操作后, 并寻找出最优秀个体然后加以保留。

Step 8: 判断是否达到终止条件: 若达到终止条件则跳转至 Step 9, 若未到达终止条件则跳转至 Step 4。

Step 9: 获取 BP 神经网络结构。

Step 10: 对 DE-BP 神经网络焦炭质量模型进行训练。

差分算法优化 BP 神经网络训练流程图, 如图 2 所示。

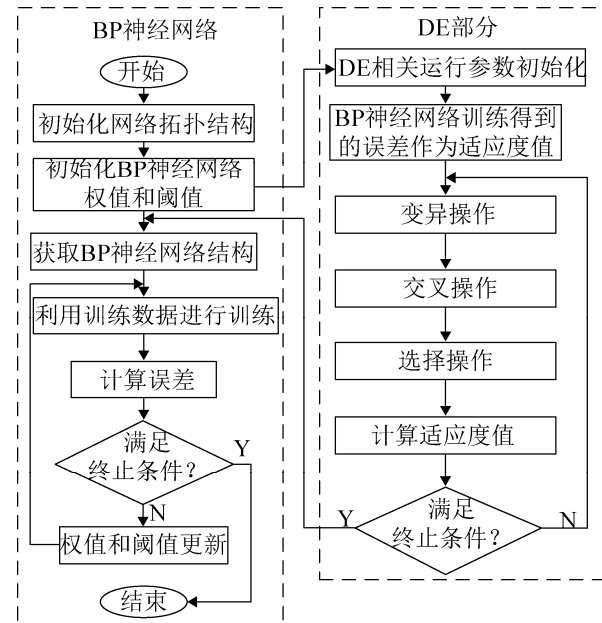


图 2 DE-BP 神经网络训练流程图

Fig. 2 DE-BP neural network training flowchart

3 焦炭质量预测

从实际生产中筛选出 150 组焦炭质量指标指标与入煤指标作为预测模型的训练数据, 另外选取 30 组作为测试数据。将训练数据在 MTLAB 中先做归一化处理作为输入、输出数据来对预测模型进行训练。

为了充分发挥每一个变量的影响力, 更加准确的体现其贡献, 对训练数据和预测数据采用了归一化的处理, 使数据都处于 $[0,1]$ 区间, 样本的数据按公式(4)进行处理:

$$\tilde{x} = a + b \times \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中: x_{\max} , x_{\min} 为每组样本中的最大值和最小值; a , b 是常值; x 为归一化前的变量值; \tilde{x} 为归一化后的变量值。

为了与实际生产参数相符, 还要对得到的预测

样本完成反归一化处理。反归一化公式为：

$$x = \frac{1}{b}(\tilde{x} - a)(x_{\max} - x_{\min}) + x_{\min} \quad (5)$$

采用 BP 神经网络训练出的误差曲线如图 3 所示，其中 Performance=0.000 999 6 在经过 6 784 次训练 epoch 之后，就达到我们所设定的总迭代误差 mse<0.001。

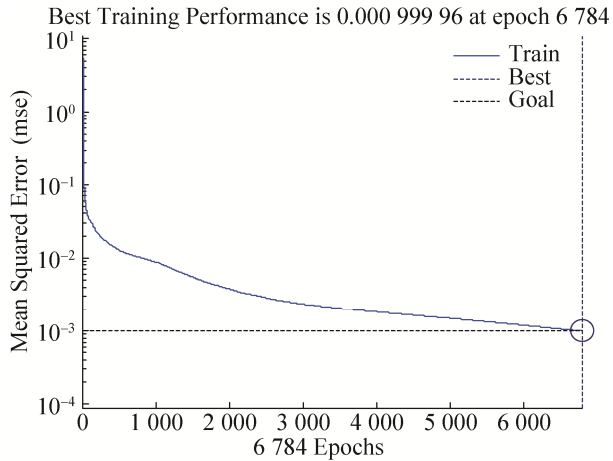


图 3 BP 训练误差曲线
Fig. 3 BP training error curve

差分算法优化 BP 神经网络中，在 BP 神经网络部分参数设置相同，而在差分算法部分种群大小 N 取 30，为了保证算法的优化能力所选取的缩放因子 $F=0.5$ ，交叉概率 CR 取 0.3，最大进化代数 t_{\max} 取 50。得到 DE-BP 训练误差曲线如图 4 所示。其

中，Performance=0.000 999 44，在经过 1270 次训练 epoch 之后，就达到我们所设定的总迭代误差 mse<0.001。对比图 3，本文采用的差分算法优化 BP 神经网络的收敛速度较快。




图 4 DE-BP 训练误差曲线
Fig. 4 DE-BP training error curve


为了验证优化后的焦炭质量预测模型能够反应实际应用情况，从生产运行数据库里选取焦炭质量的实测值作为验证数据，表 1 与表 2 分别表示 BP 预测模型与 DE-BP 预测模型部分测试数据的误差，基于 DE-BP 优化算法焦炭质量预测各项指标对比如图 5 所示。

表 1 BP 模型预测值与实际值对比
Tab. 1 BP model predicted value and the actual value comparison

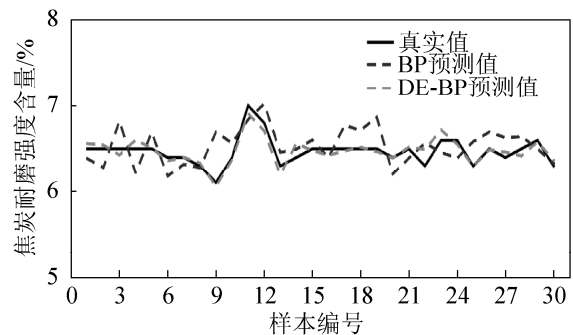
硫分/%			灰分/%			抗碎强度/%			耐磨强度差/%		
实测值	预测值	误差	实测值	预测值	误差	实测值	预测值	误差	实测值	预测值	误差
0.48	0.50	0.02	12.31	12.54	0.23	84.00	83.68	0.32	6.50	6.38	0.12
0.51	0.54	0.03	12.52	12.44	0.08	83.80	84.15	0.35	6.50	6.28	0.22
0.55	0.60	0.05	12.00	12.17	0.17	83.60	84.65	1.05	6.50	6.82	0.32
0.55	0.61	0.06	12.13	12.53	0.40	83.80	83.31	0.49	6.50	6.21	0.29
0.53	0.63	0.10	12.38	12.21	0.17	83.80	84.17	0.37	6.50	6.69	0.19
0.53	0.55	0.02	12.16	12.40	0.24	83.30	84.08	0.78	6.40	6.18	0.22
0.54	0.52	0.02	12.01	12.17	0.16	83.90	82.79	1.11	6.40	6.32	0.08
0.50	0.63	0.13	11.97	12.86	0.89	84.20	86.51	2.31	6.30	6.26	0.04
0.53	0.56	0.03	12.12	12.01	0.11	84.10	83.01	1.09	6.10	6.69	0.59
0.53	0.48	0.05	12.30	12.42	0.12	82.30	84.59	2.29	6.40	6.57	0.17

表 2 DE-BP 模型预测值与实际值对比
Tab. 2 DE-BP model predicted value and the actual value comparison


硫分/%			灰分/%			抗碎强度/%			耐磨强度差/%		
实测值	预测值	误差	实测值	预测值	误差	实测值	预测值	误差	实测值	预测值	误差
0.48	0.46	0.02	12.31	12.49	0.18	84.00	84.25	0.25	6.50	6.56	0.06
0.51	0.53	0.02	12.52	12.58	0.06	83.80	83.63	0.17	6.50	6.54	0.04
0.55	0.53	0.02	12.00	12.15	0.15	83.60	84.02	0.42	6.50	6.50	0.00
0.55	0.56	0.01	12.13	12.43	0.30	83.80	83.63	0.17	6.50	6.51	0.01
0.53	0.54	0.01	12.38	12.41	0.03	83.80	83.57	0.23	6.50	6.50	0.00
0.53	0.51	0.02	12.16	12.32	0.16	83.30	83.56	0.26	6.40	6.36	0.04
0.54	0.54	0.00	12.01	12.16	0.15	83.90	83.68	0.22	6.40	6.39	0.01
0.50	0.54	0.04	11.97	12.21	0.24	84.20	83.77	0.43	6.30	6.32	0.02
0.53	0.52	0.01	12.12	12.17	0.05	84.10	84.37	0.27	6.10	6.31	0.21
0.53	0.53	0.00	12.30	12.33	0.03	82.30	82.28	0.02	6.40	6.37	0.03




(a) 焦炭质量灰分对比曲线



(b) 焦炭质量耐磨强度对比曲线



(c) 焦炭质量硫分对比曲线



(d) 焦炭质量抗碎强度对比曲线

图 5 焦炭质量预测各项指标对比图

Fig. 5 Coke quality forecast indicators comparison chart

对于焦炭质量预测的四个指标: 硫分 S_{id} 、灰分 A_d 、抗碎强度 M_{40} 以及耐磨强度 M_{10} , 由表 1、表 2 与图 5 可知, BP 预测模型预测值与实测值相比, 精度分别为 0.02%~0.13%、0.08%~0.89%、0.32%~2.31%、0.04%~0.59%, DE-BP 预测模型预测值与实测值相比, 精度分别为 0~0.04%、0.03%~0.24%、0.02%~0.43%、0~0.21%。综合两种

预测模型对比结果, DE-BP 模型较 BP 神经网络模型的预测准确率要好, 满足设计要求。

4 结论

本文分析了焦炭质量预测模型的影响因素, 建立了基于 DE-BP 神经网络预测模型, 运用差分进化算法对神经网络初始权值和阈值优化, 减小其

随机性,提高了所建模型的预测精度。预测效果表明收敛速度快,具有较高的预测精度,可以满足生产工艺的要求,为解决综合生产指标的优化控制提供了有益的参考价值。

参考文献:

- [1] 薛改凤, 项茹, 陈鹏, 等. 炼焦煤质量指标评价体系的研究[J]. 武汉科技大学学报, 2009, 32(1):36-40.
XUE Gai-feng, XIANG Ru, CHEN Peng, et al. Index System for Evaluating the Quality of Coking Coal[J]. Journal of Wuhan University of Science and Technology, 2009, 32(1): 36-40.
- [2] 邓志平, 张代林. 优化配煤及焦炭质量的研究探讨[J]. 江西冶金, 2014, 34(4): 1-3.
DENG Zhi-ping, ZHANG Dai-lin. Study on Optimization of Coal Blending and Coke Quality[J]. Jiangxi Metallurgy, 2014, 34(4): 1-3.
- [3] 于青, 王德全, 吴子良, 等. 焦炭反应性和反应后强度的关系及其影响因素研究[J]. 中国冶金, 2012, 22(3): 10-14.
YU Qing, WANG De-quan, WU Zi-liang, et al. Relationship Between Coke Reactivity and Strength After Reaction and Research of Influence Factor[J]. China Metallurgy, 2012, 22(3): 10-14.
- [4] 曹密静, 王胜春, 贾万福. 焦炭灰分与硫分的预测[J]. 燃料与化工, 2012, 43(5): 14-16.
CAO Mi-jing, WANG Sheng-chun, JIA Wan-fu. Prediction for Ash and Sulfur Content of Coke[J]. Fuel & Chemical Processes, 2012, 43(5): 14-16.
- [5] 刘颖义, 穆红旺, 张淑会. 焦炭质量预测模型的建立[J]. 中国冶金, 2012, 22(1): 28-31.
LIU Ying-yi, MU Hong-wang, ZHANG Shu-hui. Establish of Prediction Mode of Coke Quality[J]. China Metallurgy, 2012, 22(1): 28-31.
- [6] 谢海深, 刘永新, 孟军波, 等. 焦炭质量预测模型的研究[J]. 煤炭转化, 2006, 29(3): 54-57.
XIE Hai-shen, LIU Yong-xin, MENG Jun-bo, et al. Study on The Predictive Model for Coke Quality[J]. Coal Conversion, 2006, 29(3): 54-57.
- [7] 刘俊, 张学东, 刘宏, 等. 基于 BP 神经网络的焦炭质量预测[J]. 燃料与化工, 2006, 37(6): 12-15.
LIU Jun, ZHANG Xue-dong, LIU Hong, et al. Prediction of Coke Quality Based on BP Neural Network[J]. Fuel & Chemical Processes, 2006, 37(6): 12-15.
- [8] 雷琪, 刘君贤, 何勇, 等. 基于 PCA 与 RBF 的焦炭质量预测模型[J]. 控制工程, 2010, 17(4): 513-520.
LEI Qi, LIU Jun-xian, HE Yong, et al. A Prediction Mode for Coke Quality Based on PCA and RBF[J]. Control Engineering of China, 2010, 17(4): 513-520.
- [9] 覃光华, 李祚泳. BP 网络过拟合问题研究及其应用[J]. 武汉科技大学学报, 2006, 39(6): 55-58.
QIN Guang-hua, LI Zuo-yong. Over-fitting of BP NN Research and Its Application[J]. Engineering Journal of Wuhan University, 2006, 39(6): 55-58.
- [10] 田英奇, 张卫华, 沈寓韬, 等. 镜质组反射率指导优化配煤炼焦方案的研究[J]. 煤炭科学技术, 2016, 44(4): 162-168.
TIAN Ying-qi, ZHANG Wei-hua, SHEN Yu-tao, et al. Research on optimization of coal blending coking guided by vitrinite reflectance[J]. Coal Science and Technology, 2016, 44(4): 162-168.
- [11] 周洪, 闵礼书, 邹祥林. 基于神经网络的特大型焦炉焦炭质量预测研究[J]. 系统仿真学报, 2009, 21(6): 1543-1552.
ZHOU Hong, MIN Li-shu, ZOU Xiang-lin. Research on Prediction of Blended Coal for Coking Quality in Oversized Coke Furnace Based on Neural Network[J]. Journal of System Simulation, 2009, 21(6): 1543-1552.
- [12] 贺毅朝, 王熙照, 刘坤起. 差分算法演进的收敛性分析与算法改进[J]. 软件学报, 2010, 21(5): 875-885.
HE Yi-chao, WANG Xi-zhao, LIU Kun-qi. Convergent Analysis and Algorithmic Improvement of Differential Evolution[J]. Journal of Software, 2010, 21(5): 875-885.
- [13] 汪慎文, 丁立新, 张文生, 等. 差分进化算法研究进展[J]. 武汉大学学报(理学版), 2014, 60(4): 283-292.
WANG Shen-wen, DING Li-xin, ZHANG Wen-sheng, et al. Survey of Differential Evolution[J]. Journal of Wuhan University (Natural Science Edition), 2014, 60(4): 283-291.
- [14] Das S, Suganthan P N. Differential Evolution: A Survey of the State-of-the-Art[J]. IEEE Trans. Evolut. Comput. (S1089-778X), 2011, 15(1): 4-31.
- [15] Li Gaoyang, Liu Mingguang. The Summary of Differential Evolution Algorithm and its Improvements [C]// 2010 3rd International Conference on Advanced Computer Theory and Engineering (ICACTE), Chengdu, China. 2010: 153-156.