

粒子群优化 BP 神经网络飞灰可燃物预测建模

吕 太,郭志清

(东北电力大学 能源动力与工程学院,吉林 132012)

摘 要:用 PSO 算法对 BP 神经网络结点间的连接权值和阈值进行优化,建立 PSO 优化 BP 神经网络模型(简称 PSO - BP 模型)。此模型充分发挥了粒子群算法的全局寻优能力和 BP 算法的局部搜索优势。利用某 670 t/h 锅炉运行参数对锅炉飞灰可燃物进行预测。结果显示 PSO - BP 模型比 BP 神经网络模型预测值更精确,收敛速度更快,为大型电厂锅炉飞灰可燃物的分析和预测提供了一条可行的方法。

关 键 词:BP 神经网络;飞灰可燃物;粒子群优化;建模

中图分类号: O242;TK229.6 文献标识码: A

引 言

在锅炉热效率的反平衡计算中,飞灰可燃物含量作为固体不完全燃烧损失中的重要一项,是影响锅炉效率的关键因素之一。由于飞灰可燃物受锅炉设计形式、结构特征、燃烧煤种、运行参数等多种因素影响,且各因素与飞灰可燃物含量之间关系复杂,呈现多维非线性关系^[1~2]。在实际计算中,一般由锅炉尾部烟道取得燃烧飞灰样品,采用热重法实际测量飞灰可燃物含量,但由于化验飞灰可燃物含量的实验滞后于燃烧工况,所以对运行人员的指导作用减弱^[3~5]。

现在有很多研究利用神经网络作为飞灰可燃物预测的有效工具,取得了很大的研究成果^[6]。BP (Back Propagation) 神经网络被应用的最多,但 BP 神经网络也存在一定的自身缺陷,比如说极易陷入局部极值点和收敛速度慢。本研究利用粒子群算法 (Particle Swarm Optimization, PSO) 优化 BP 神经网络,通过优化调整 BP 神经网络的各结点间的连接权值和结点阈值,使得预测的结果更加快速和准确。最后利用建立起来的 PSO - BP 模型对某电厂飞灰可燃物进行预测,并对比 BP 网络模型的预测值。结果显示 PSO - BP 模型预测结果更准确、更快速、更适合工程应用。

1 粒子群(PSO)算法

具体算法为:设在 N 维目标搜索空间中,有 m 个粒子组成了一个种群,第 i 个粒子的位置向量为: $X_i = (X_{i1}, X_{i2}, \dots, X_{iN})$ $i = 1, 2, \dots, m$; 速度向量为: $V_i = (V_{i1}, V_{i2}, \dots, V_{iN})$ 。第 i 个粒子的最优位置为: $P_i = (P_{i1}, P_{i2}, \dots, P_{iN})$; 整个粒子群目前搜索到的最优位置为: $P_g = (P_{g1}, P_{g2}, \dots, P_{gN})$; 粒子的更新公式为:

$$V_{in}(t+1) = w_1 \times V_{in}(t) + c_1 \times r_1 \times (P_{in} - X_{in}(t)) + c_2 \times r_2 \times (P_{gn} - X_{in}(t)) \quad (1)$$

在式(1)中,速度更新分为三个部分:第一部分:当前速度的影响,加入惯性因子起到全局和局部的平衡作用;第二部分:粒子本身的记忆影响;第三部分:反映社会群体信息的影响,体现了粒子之间的信息合作和共享^[7],即:

$$X_{in}(t+1) = X_{in}(t) + V_{in}(t+1) \quad (2)$$

$$\text{当 } V_{in} > V_{\max} \text{ 时,取 } V_{in} = V_{\max} \quad (3)$$

$$\text{当 } V_{in} < -V_{\max} \text{ 时,取 } V_{in} = -V_{\max} \quad (4)$$

$$w_1 = w_{\text{star}} - (w_{\text{star}} - w_{\text{end}}) \times j / \text{popsize} \quad (5)$$

式中: $i = 1, 2, \dots, m$; $n = 1, 2, \dots, N$; 加速常数 c_1 和 c_2 —非负常数; r_1 和 r_2 服从 $[0, 1]$ 区间上的均匀分布随机数; V_{in} 在 $-V_{\max}$ 与 $+V_{\max}$ 之间; w_1 —惯性权重因子, w_{star} —权重因子开始时的值, w_{end} —权重因子结束时的值, j —目前的迭代次数, popsize —总的迭代次数。 w_1 大则具有全局搜索的能力更强, w_1 小则局部搜索的能力强。

2 粒子群优化 BP 网络

2.1 粒子群优化 BP 神经网络方法

BP 神经网络属于典型的前馈型神经网络,网络的组织学习过程主要包括网络内部的前向计算和误

收稿日期: 2012 - 08 - 08; 修订日期: 2012 - 10 - 24

作者简介: 吕 太(1957 -),男,吉林人,东北电力大学教授。

差的反向传播计算。BP 神经网络存在自身的缺点: 首先, 它的收敛速度慢; 其次, 容易陷入局部极值点; 再者, BP 神经网络对初始权值、学习率等参数敏感, 各参数需要不断训练才能固定, 训练过度会提高网络的拟合性, 使得各参数包含某些特殊样本的信息以及干扰噪声等信息, 以致发生“过拟合”的现象, 最终影响网络的泛化能力。粒子群(PSO)算法具有鲁棒性高、收敛速度快、全局搜索能力强的特点^[8]。用它来优化 BP 神经网络的连接权值和阈值, 不但能发挥神经网络的泛化能力, 克服 BP 神经网络存在的种种问题, 同时还能有效地提高神经网络的学习能力和收敛速度。神经网络优化算法一般来说可分为 3 种方法, 即: 优化权值和阈值、优化网络结构和同时优化权值和阈值以及网络结构。本研究采用第一种方法, 即利用粒子群(PSO)优化 BP 神经网络的连接权值和阈值。

2.2 粒子群优化 BP 神经网络算法设计中的关键点

2.2.1 BP 神经网络连接权值和阈值同粒子群中粒子的维度空间之间的映射关系

我们将神经网络中的每一个连接权值和阈值分别对应于粒子群中每个粒子的维度分量, 使其具有一一对应的映射关系。通俗理解为 BP 神经网络有多少个连接权值和阈值, 粒子群(PSO)算法中的各个粒子就对应有多少维。举个例子, 对于一个拓扑结构为 $a-b-c$ 的三层 BP 神经网络, 网络共有权值和阈值为: $(a \times b + b \times c + b + c)$, 对应的粒子群(PSO)算法中的各粒子的维度也应是: $(a \times b + b \times c + b + c)$ 。

2.2.2 粒子群(PSO)适应度函数的确定

适应度函数一般用神经网络的均方和误差, 通过粒子群(PSO)的优化, 在全局搜索最优值, 使网络的均方和误差最小, 即:

$$G = \frac{1}{CM} \sum_{i=1}^M \sum_{j=1}^C (y_{ji}^D - y_{ji})^2 \quad (6)$$

式中: M —总样本数; C —网络中输出的神经元个数; y_{ji}^D —第 i 个样本第 j 个输出神经元的理想输出值; y_{ji} —第 i 个样本的第 j 个输出神经元的实际输出值。

2.2.3 粒子群各参数取值确定

粒子群的本身参数较多, 主要包括: 加速常数 c_1 和 c_2 ; 惯性权重因子 w_1 , 惯性权重因子又包括开始值 w_{star} 和结束值 w_{end} ; 迭代次数 $popsize$ 等参数。各

参数的确定没有统一的现成公式, 必须要根据训练结果最终来确定其最终的取值。

2.3 粒子群优化 BP 神经网络算法的流程

(1) 建立 BP 神经网络模型;

(2) 初始化粒子群算法各参数, 选定粒子数、迭代次数、加速常数、惯性权重因子、粒子维数、适应值阈值、粒子的初始位置和速度、粒子的最大最小位置和速度值等;

(3) 把 BP 神经网络模型连接权值和阈值同粒子群(PSO)中粒子的维度空间之间建立映射关系;

(4) 将初始化后的各粒子的各维度值代入预先建好的神经网络, 根据式(6)计算各自的适应度函数的值, 选出其中适应度函数值最小的粒子的位置设为最佳位置。

(5) 根据式(1)~式(5)来更新粒子的位置和速度。

(6) 判断计算迭代次数和适应度函数值, 如果迭代次数大于预先设定的迭代次数或者适应度函数值小于适应度阈值, 则终止迭代; 如果没有达到条件则重新执行第 4、5、6 步骤, 直到满足设定条件为止。

(7) 将全局最优粒子维度值映射为神经网络权值和阈值, 将其作为优化的结果来训练 BP 神经网络, 得到最终的神经网络的预测结果。

3 飞灰可燃物预测模型建立

在对某四角切圆 670 t/h 煤粉炉进行多工况热态测试的基础上, 应用人工神经网络为手段, 建立飞灰可燃物含量 BP 神经网络预测模型。然后利用粒子群(PSO)优化 BP 神经网络算法改进建立的神经网络模型, 建立新的 PSO-BP 预测模型。PSO-BP 模型收敛速度更快、预测误差更小、泛化能力更强。以上所有程序借助 MATLAB 予以实现。

3.1 BP 神经网络模型

BP 神经网络模型建立的关键点是网络输入、输出参数的确定和网络结构的设计。对某一特定的锅炉, 各运行系统都正常的情况下, 飞灰可燃物含量的多少与锅炉的运行状态参数必定存在着一个相对稳定的统计对应关系。从运行实践可知, 飞灰可燃物含量主要取决于锅炉负荷、燃烧调整和煤质^[9]。锅炉负荷主要受发电负荷、主蒸汽压力、主蒸汽温度等参数的影响; 燃烧调整主要受炉膛出口氧量、排烟温度等参数的影响; 煤质变化主要取决于干燥基灰分、

收到基低位发热量、干燥无灰基挥发分等参数。影响飞灰可燃物含量的因素较多，模型选取时，要适当简化，考虑选取主要因素。

基于上述原因，本模型的输入参数共选取 8 个，即发电负荷、主蒸汽压力、主蒸汽温度、排烟温度、炉膛出口氧量、干燥基灰分、收到基低位发热量、干燥无灰基挥发分。将飞灰可燃物含量作为神经网络的单一输出参数。

模型采样样本为锅炉不同工况负荷下实际运行

样本，涵盖锅炉正常运行各种运行状态，具有代表性。最后确定训练样本共取 60 个，检验样本 14 个。网络结构选用三层，分别为输入层、中间层和输出层^[10]。具体结构为：8-10-1，也即 8 个输入单元，10 个中间单元，1 个输出单元。训练次数：10000；学习率：0.1；训练目标：0.0001。中间层传递函数；输出层传递函数；网络学习函数。实验数据如表 1 所示，预测结果如图 1 所示。

表 1 BP 神经网络输入的实际工况运行参数表

Tab. 1 Table of the operation parameters under the actual operating condition inputed from the BP neural network

| 项目 | 发电量 /kWh | 氧量 /% | 排烟 /℃ | 主蒸汽压力 /MPa | 主蒸汽温度 /℃ | 干燥基灰分 /% | 干燥无灰基挥发分 /% | 收到基低位发热量 /kJ · kg ⁻¹ |
|-----|----------|-------|-------|------------|----------|----------|-------------|---------------------------------|
| 1 | 157 | 5.36 | 132 | 13.22 | 537 | 44.36 | 32.47 | 14933 |
| 2 | 168 | 4.76 | 129 | 13.17 | 535 | 43.7 | 33.36 | 15230 |
| 3 | 157 | 5.42 | 131 | 13.21 | 536 | 47.03 | 30.76 | 15311 |
| 4 | 154 | 5.36 | 133 | 13.22 | 537 | 45.8 | 38.12 | 15264 |
| 5 | 152 | 5.25 | 131 | 13.2 | 534 | 44.53 | 35.75 | 16134 |
| 6 | 146 | 5.4 | 124 | 13.18 | 536 | 44.84 | 36.01 | 16043 |
| 7 | 150 | 4.89 | 133 | 13.18 | 537 | 43.58 | 33.29 | 15676 |
| 8 | 148 | 4.79 | 133 | 13.19 | 537 | 46.7 | 36.29 | 15686 |
| 9 | 152 | 4.77 | 134 | 13.21 | 536 | 45.25 | 26.82 | 15545 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 74 | 182 | 4.4 | 140 | 13.16 | 536 | 49.36 | 31.42 | 15255 |

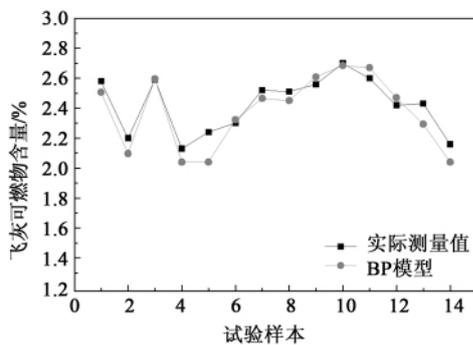


图 1 BP 模型飞灰可燃物预测值与实测值对比图
Fig. 1 Chart showing a comparison of the predicted values by using the BP model and the actually measured ones of the flammables in the flying ash

从图 1 可知，用 BP 神经网络模型预测飞灰可燃物含量值与实测值之间差距不大，预测值基本与实测值相符。预测值绝对误差在 -0.1999 和 0.0710 之间波动。预测值相对误差最大值为

8.9257%，小于 10%，其它相对误差均在 5% 以内。从以上数据分析，BP 神经网络模型预测飞灰可燃物含量基本达到工业应用要求，但有个别值较大，需要进一步改进。

3.2 粒子群(PSO) 模型

PSO 参数设置：最大迭代次数为 1000，种群规模为 20，个体最大值 1，个体最小值 -1，最大速度 1，最小速度 -1，权重因子开始值 0.9，权重因子终止值 0.4，初始化粒子位置系数 0.5，初始化速度系数 0.3，加速常数 c_1 为 1.5 和 c_2 为 1.5。

3.3 建立 BP 神经网络模型连接权值和阈值同粒子群(PSO) 模型中粒子的维度空间建立映射关系

粒子群维度空间维度为： $N = 8 \times 10 + 10 + 10 \times 1 + 1 = 101$ 。其中前 1~80 维度为输入层到中间层的连接权值；81~90 维度为中间层阈值；91~100 维度为中间层到输出层之间连接权值；101 维度为输出层阈值。

3.4 粒子群 (PSO) 优化 BP 神经网络模型运行结果

PSO 优化迭代过程如图 2 所示。

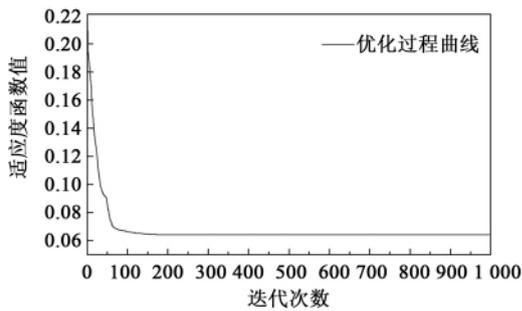


图 2 粒子群优化 BP 神经网络优化过程曲线图

Fig. 2 Curves showing the optimization process by using a particle cluster optimized BP neural network

从图中可以看出,迭代开始后适应度函数值下降很快,在 120 次迭代后,适应度函数值趋于稳定,最终的函数值稳定在大约 0.065 左右。

根据粒子群优化后的权值和阈值重新设置 BP 神经网络的权值和阈值,用新参数模型再次预测飞灰可燃物含量。

从图 3 可知,用 PSO - BP 模型预测飞灰可燃物含量值与实测值之间差距较小,预测值与实测值相符较好。预测值绝对误差均较小,在 -0.0674 和 0.0636 之间波动。预测值相对误差最大值为 3.1635%, 小于 5%, 其它预测值均在 3% 以下。从以上数据分析,PSO - BP 模型预测飞灰可燃物含量完全达到工业应用要求。

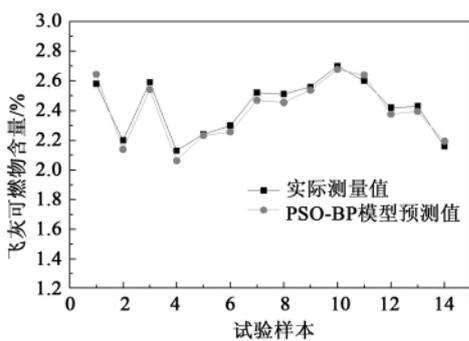


图 3 PSO - BP 模型飞灰可燃物预测值和实际值对比图

Fig. 3 Chart showing a comparison of the predicted values by using the PSO - BP model and the actually measured ones of the flammables in the flying ash

对比 BP 模型和 PSO - BP 模型更能看出 PSO -

BP 模型的优越性。

从图 4 可以看出, BP 神经网络模型和 PSO - BP 模型均能较为准确的预测飞灰可燃物含量值,但 PSO - BP 模型的预测值更加贴近实测值。

图 5 中的绝对值误差对比图和图 6 中的相对误差对比图也均能看出, PSO - BP 模型比 BP 模型波动更小,误差更小。

模型性能指标如下:

均方根相对误差:

$$e_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left[\frac{A(i) - F(i)}{A(i)} \right]^2} \quad (7)$$

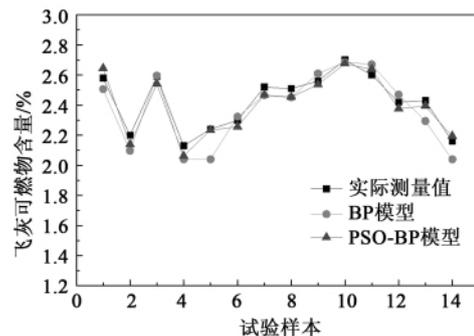


图 4 BP 模型和 PSO - BP 模型飞灰可燃物预测值与实测值对比图

Fig. 4 Chart showing a comparison of the predicted values by using the BP and PSO - BP model and the actually measured ones of the flammables in the flying ash

最大相对误差:

$$E_{max} = \max(|A(i) - F(i)|) \quad (8)$$

式中: n —实验样本数; $A(i)$ —实际飞灰可燃物含量; $F(i)$ —预测飞灰可燃物含量。

从表 2 中可知, PSO 优化 BP 神经网络模型飞灰预测值的均方根相对误差、最大相对误差和耗时均要小于 BP 神经网络模型,前者模型在飞灰可燃物预测的应用中更有优势,精度更高,耗时更少,更有利于实际应用。

表 2 PSO - BP 模型和 BP 模型预测结果对比表

Tab. 2 Table for comparing the results predicted by using the PSO - BP and BP model

| 模型 | 均方根相对误差 (e_{MSE}) | 最大相对误差 (E_{max}) | 耗时/s |
|----------|--------------------------|-------------------------|------|
| BP | 0.0393 | 0.1999 | 32.5 |
| PSO - BP | 0.0191 | 0.0674 | 19.7 |

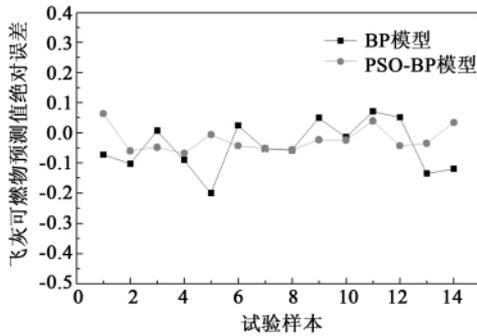


图5 BP模型和 PSO-BP模型绝对误差对比图

Fig.5 Chart showing a comparison of the absolute errors between values calculated by using the BP and PSO-BP model

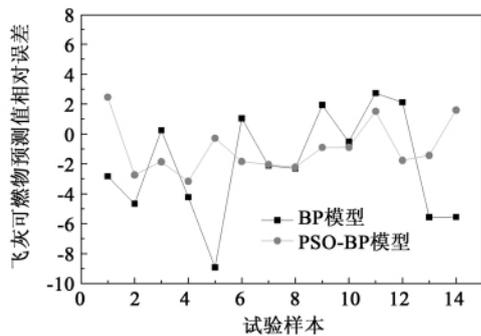


图6 BP模型和 PSO-BP模型相对误差对比图

Fig.6 Chart showing a comparison of the relative errors between values calculated by using the BP and PSO-BP model

4 结 论

(1) 飞灰可燃物含量受到如锅炉负荷、煤种、炉温、过剩空气系数、煤粉细度、炉型等多种因素的影响,且各个影响因素间关系较为复杂。本研究以四角切圆 670 t/h 粉煤炉为例 提取运行参数中重要的八个参数作为神经网络的输入值,用飞灰可燃物含量作为网络模型的输出值 通过实践证明这种选取方法是可行的,是对复杂变量的合理简化,实际运用中也完全能够达到预测飞灰含碳量的目的。

(2) 鉴于 BP 神经网络自身存在的缺点,应用粒子群(PSO)算法,建立粒子的维度和神经网络连接权值及阈值之间的映射关系,根据适应度函数值优化 BP 网络的连接权值和阈值。优化后的 BP 神经网络模型较之前的 BP 神经网络具有更好的性能指标,收敛速度更快。

(3) 通过粒子群(PSO)优化 BP 神经网络算法建立了一种大型发电厂锅炉飞灰可燃物含量预测的实用模型即 PSO-BP 模型,可根据锅炉实际的运行参数预测锅炉的飞灰可燃物含量,为锅炉的经济燃烧提供了可靠依据。

(4) 本研究在实践中能够做到对飞灰可燃物含量的实时监测,一改传统飞灰可燃物含量测试方法中测试结果时间严重落后于实际运行时间的情况,提供了一种切实可行的在线监测方法,具有一定的工业应用前景和价值。

参考文献:

- [1] 周 昊 朱洪波 曾庭华 等.基于神经网络的大型电厂锅炉飞灰含碳量建模 [J].中国电机工程学报 2002 22(6):96-100.
ZHOU Hao ,ZHU Hong-bo ,ZENG Ting-hua ,et al. Modeling of a large-sized utility boiler based on the artificial neural network [J]. Proceedings of China Electric Machinery Engineering ,2001 ,22 (6) :96-100.
- [2] Styszko G K ,Golas J ,Jankowski H ,et al. Characterization of the coal fly ash for the purpose of improvement of industrial on-line measurement of unburned carbon content [J]. Fuel ,2004 ,83 (13) :1847-1853.
- [3] 王 涛 张春龙 吴 楠 等.失重法飞灰测碳仪及其存在问题与改进途径 [J].节能 2012 4:65-68.
WANG Tao ZHANG Chun-long ,WU Nan ,et al. Weight loss method-based flying ash carbon meter and its existing problems and remedies [J]. Energy Conservation 2012 4:65-68.
- [4] Fan Maohong ,Brown R C. Precision and accuracy of photo acoustic measurements of unburned carbon in fly ash [J]. Fuel ,2001 ,80 (11) :1545-1554.
- [5] Ouazzane A K ,Castagner J L ,Jankowski H ,et al. Characterization of the coal fly ash for the purpose of improvement of industrial on-line measurement of unburned carbon content [J]. Fuel ,2004 ,83 (13) :1847-1853.
- [6] Sebastia M ,Olmo I F ,Irabien A. Neural network prediction of unconfined compressive strength of coal fly ash cement mixtures [J]. Cement and Concrete Research 2003 33(8) :1137-1145.
- [7] 魏秀业 潘宏侠.粒子群优化及智能故障诊断 [M].北京:国防工业出版社 2010.
WEI Xiu-ye PAN Hong-xia. Particle luster optimization and intelligent fault diagnosis [M]. Beijing: National Defense Industry Press 2010.
- [8] 纪 震 廖慧连 吴青华.粒子群算法及应用 [M].北京:科学出版社 2009.
JI Zhen ,LIAO Hui-lian ,WU Qing-hua. Particle cluster algorithm and its applications [M]. Beijing: Science Press 2009.
- [9] 陈 彪 丁艳军 吴占松.670 t/h 煤粉炉飞灰含碳量的神经网络预测建模 [J].电站系统工程 2005 21(6) :17-20.
CHEN Biao ,DING Yan-jun ,WU Zhan-song. Prediction and modeling of the carbon content of flying ash fom a 670 t/h pulverized coal-fired boiler [J]. Power Plant System Engineering ,2005 ,21 (6) :17-20.
- [10] Hechi Nielsen R. Theory of the back propagation neural network [M]. Las Vegas ,Nevada: Proc of IJCNN ,1989 ,1:593-603.

(辉 编辑)

law governing the influence of the pyrolytic temperature on the coal tar productivity ,coal gas constituents ,coal tar constituents was obtained respectively: the temperatures corresponding to the highest yields of coal tar from the above-mentioned three types of coal were 481 °C ,519 °C and 514 °C respectively and the coal tar yields were 13.58% ,12.54% and 4.23% respectively. The H₂ and CH₄ productivities of the three types of coal increased with an increase of the temperature while the CO productivity of the oil shale rock attained its maximum at 490 °C and then decreased with an increase of the temperature. The carbon dioxide productivities of the three types of coal were all influenced little by the temperature. At various pyrolytic temperatures ,Grade No. 6 coal had relatively high productivities of hydroxybenzene and benzene derivatives. When the temperature was 440 °C ,the long chain hydrocarbons of the coal fed into the furnace for coal gas production approximately took up 50% of the coal tar in weight.

Key words: coal pyrolysis ,pyrolytic temperature ,coal tar ,coal gas

探讨用于气固多相流检测的广义动态重建算法 = **Exploratory Study of the Generalized Dynamic Rebuilding Algorithm for Testing and Measuring a Gas-solid Multi-phase Flow** [刊 ,汉] WANG Ze-pu ,LIU Shi ,ZHOU Lei (College of Energy Power and Engineering ,North China University of Electric Power ,Beijing ,China ,Post Code: 102206) ,CHEN Jiang-tao (Beijing Subcompany ,China Tianchen Engineering Co. Ltd. ,Beijing ,China ,Post Code: 100029) //Journal of Engineering for Thermal Energy & Power. - 2013 28(2) . - 177 ~ 181

Through monitoring the flow speed and rate of a gas-solid two phase flow ,the flow characteristics of the fluid transmitted was clarified and the pneumatic transmission process was successfully performed. The capacitance topography technology is regarded as one of technologies for detecting a gas-solid two phase flow and the key lies in its image rebuilding link. Through choosing a proper image rebuilding algorithm ,one can reversely deduct the distribution characteristics of the fluid transmitted in a section. To improve the rebuilding image quality of the ECT system and enhance the accuracy of the detection technology ,presented was a generalized dynamic image rebuilding algorithm integrating the space restriction ,time restriction and reverse deduction information of the fluid flow. By analyzing and comparing the numerical test and the conventional image rebuilding algorithm ,the authors believe that the image structure rebuilt by using the algorithm in question should be clearest. The test showed the pulverized coal and ash pneumatic transmission process as reversely deducted by using the algorithm in question. Both coal and ash obviously embodied the advantage of the dynamic rebuilding algorithm. **Key words:** electric capacitance topography (ECT) ,generalized dynamic rebuilding algorithm ,gas-solid two-phase flow ,annular flow ,bubble flow

粒子群优化 BP 神经网络飞灰可燃物预测建模 = **Modeling for Predicting the Flammable Content of Fly Ash Base on a Particle Swarm Optimized Back Propagation Neural Network** [刊 ,汉] LU Tai ,GUO Zhi-qing(College of Energy Power and Engineering ,Northeast University of Electric Power ,Jilin ,China ,Post Code: 132012) // Journal of Engineering for Thermal Energy & Power. -2013 28(2) . - 182 ~ 186

The magnitude of the flammable content of fly ash represents one of the important factors influencing the efficiency of a boiler and plays an important role in economic operation of the boiler. The authors optimized the linking weight value and threshold one between the nodes of a BP neural network by using the PSO (particle swarm optimization) algorithm and established a BP neural network-based model optimized by using the PSO algorithm (called as a PSO-BP model for short). The model can thoroughly give a full play of both overall optimization searching ability of the particle swarm optimization algorithm and the local searching edge of the BP algorithm. The operating parameters of a 670 t/h boiler were used to predict the flammable content of the flying ash. It has been found that compared with the BP neural network based model, the PSO-BP model is more precise and faster to come to a converging point, thus offering a feasible method for analyzing and predicting the flammable content of fly ash in large-sized utility boilers. **Key words:** BP neural network, flammable in fly ash, optimization, modeling

1 000 MW 燃煤机组的热经济学分析 = **Thermoeconomic Analysis of a 1 000 MW Coal-fired Power Generation Unit** [刊, 汉] CHENG Wei-liang, JI Hui, DI An (College of Energy Power and Mechanical Engineering, North China University of Electric Power, Beijing, China, Post Code: 102206) // Journal of Engineering for Thermal Energy & Power. - 2013, 28(2). - 187 ~ 191

To analyze in a comprehensive way the technical and economic operation characteristics of a large-sized thermal power generation unit, established was an analytic model based on the matrix mode thermoeconomics with a 1000 MW large-sized coal-fired unit serving as the object of study. By employing a thermoeconomic performance calculation software developed, to calculate, analyze and optimize the corresponding indexes were realized and at the meantime, a concept of average thermoeconomic unit cost was presented. It has been found that the exergy economic coefficients of the feedwater pumps and boilers are relatively small, indicating that their exergy losses take up relatively big proportions. The exergy economic coefficient of No. 2 high pressure heater is very high. With an increase of the live steam pressure, the average thermoeconomic unit cost will gradually decrease. With a rise of the live steam temperature, such a cost will decrease relatively quickly. When the live steam temperature or reheat temperature is 597 °C, such a cost will be down to its minimum value. **Key words:** thermoeconomics, evaluation index, cost analysis, average unit thermoeconomic cost, exergy economic coefficient

600 MW 燃煤机组锅炉大比例掺烧褐煤的设备改造 = **Equipment Modification of a 600 MW Coal-fired Boiler Mixing-dilution Burning With Lignite at a Large Proportion** [刊, 汉] WANG Liu-hu, WANG Rong, WANG Xiao-feng, et al (Inner Mongolia Jinglong Power Generation Co. Ltd., Fengzhen, China, Post Code: 012100) // Journal of Engineering for Thermal Energy & Power. - 2013, 28(2). - 192 ~ 195

Due to a big water content and low heating value of lignite, its mixing-dilution combustion in a large amount may e-