

# 基于动态 RBF 神经网络的锅炉短期负荷预测研究

戴维葆<sup>1</sup>, 邹平华<sup>1</sup>, 冯明华<sup>2</sup>, 王玉山<sup>2</sup>

(1. 哈尔滨工业大学 市政环境工程学院, 黑龙江 哈尔滨 150001;

2. 黑龙江省电力科学研究所, 黑龙江 哈尔滨 150030)

**摘 要:** 由于锅炉的热惯性, 造成整个热力系统调节相对滞后, 影响系统调峰和优化运行。因此, 根据系统参数对锅炉短期负荷进行预测变得尤为重要。在基本 RBF 神经网络的基础上, 提出了一种动态 RBF 神经网络, 并定义了样本差异和样本局部差异两个相关参数, 对新样本进行有效性判别, 同时, 给出了输入层灵敏度系数, 以实现大差异样本的负荷预测。为了验证所建模型的正确性, 以某电厂实际运行数据为基础验证了这一模型, 使用动态 RBF 神经网络对未来锅炉负荷加以预测, 同时对预测结果与实验结果进行了比较。结果表明, 这种网络具有很强的适应性, 能够对锅炉进行准确的负荷预测, 具有很好的应用前景。

**关 键 词:** 锅炉负荷; 动态 RBF 神经网络; 负荷预测; 样本差异; 样本局部差异; 输入层灵敏度系数

中图分类号: TK227 文献标识码: A

## 1 引 言

目前, 电能尚不能大量储存, 电力生产与消费又是同时进行的, 为保证电力系统的可靠性和安全性, 并从整体水平上提高电网的经济性, 在进行负荷调度时就需要机组负荷变化能够满足整个系统的要求。因此, 寻找一种有效的方法, 在锅炉运行参数的基础上进行快速、准确的负荷预测不仅能够为锅炉乃至机组的优化运行提供必要的基础, 而且也是电力系统调峰的迫切需要。锅炉短期负荷预测主要用于预测未来几分钟、几小时的锅炉负荷, 传统的短期电力负荷预测方法可分为时间序列法、回归分析法等其它方法<sup>[1~3]</sup>。近年来, 随着人工智能技术的发展, 人工神经网络(ANN)在电力负荷预测中的应用引起了人们极大的关注。文献[4]利用基本 BP 人工神经网络建立了电力负荷预测模型, 并建议用改进的 BP 网络进行负荷预测; 文献[5]将遗传算法用于神经网络结构的设计, 建立了基于遗传算法的人工神经网络负荷预测模型, 克服了 BP 人工神经网络容易收敛于局部小的缺点; 文献[6]结合小波理论

和神经网络方法进行电力系统短期负荷预报的通用模型和方法的研究, 建立了负荷预报的小波网络模型, 确定了有效的算法, 用于求解小波函数线性组合的尺度和时延参数以及神经网络的权值。

目前, 锅炉负荷预测几乎全部采用 BP 神经网络模型。这种网络通常采用的是梯度下降的连接权学习方法, 存在着收敛速度慢的固有缺陷, 从而影响了负荷预测的速度。而径向基(RBF)神经网络则不同, 由于其学习中心的初始中心是样本空间的子集, 因而, 这一过程很容易收敛, 从而实现快速的负荷预测。另外, 由于用于解决负荷预测问题的神经网络模型普遍存在着过于依赖初始数据的缺点, 本文在基本 RBF 神经网络的基础上, 提出了动态 RBF 神经网络模型, 以便有效解决这一问题, 并进行了实验验证。

## 2 RBF 神经网络

RBF 神经网络是单隐层的前向网络, 它由 3 层构成: 第一层是输入层, 第二层是隐含层, 第三层是输出层。根据隐含层的单元数, RBF 神经网络可以分为两种模型: 正规化网络(Regularization Network)和广义网络(Generalized Network)。正规化网络的隐含层单元就是训练样本, 因而正规化网络的隐含层单元数为样本数, 这对于大样本空间来说, 实现起来较为困难, 并且在求解网络的权值时容易产生病态问题。所以, 常选用广义 RBF 神经网络来解决问题, 它的隐含层单元数少于样本数。广义 RBF 神经网络的输入层有  $M$  个神经元, 其中任一神经元用  $m$  表示; 隐层有  $I$  个神经元, 任一神经元用  $i$  表示, 第  $i$  个隐单元的激励输出为“基函数” $\phi(X, t_i)$ , 其中,  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}, \dots, t_{iM}]$  ( $i=1, 2, \dots, I$ ) 为基函数中心; 输出层有  $J$  个神经元, 其中任一神经元用  $j$  表示。隐层与输出层突触权值用  $w_{ij}$  ( $i=1, 2, \dots, I; j$

$= 1, 2, \dots, J)$ 来表示。

设样本空间为:  $X = [X_1, X_2, \dots, X_k, \dots, X_N]^T$ , 任一样本  $X_k = [x_{k1}, x_{k2}, \dots, x_{km}, \dots, x_{kM}]$  对应的实际输出为  $Y_k = [y_{k1}, y_{k2}, \dots, y_{kj}, \dots, y_{kJ}]$ , 期望输出为:  $d_k = [d_{k1}, d_{k2}, \dots, d_{kj}, \dots, d_{kJ}]$ , 其中,  $k = 1, 2, \dots, N$ 。

当网络输入训练样本  $X_k$  时, 网络第  $j$  个输出神经元的实际输出为:

$$y_{kj}(X_k) = \sum_{i=1}^I w_{ij} \phi(X_k, t_i), (j = 1, 2, \dots, J) \quad (1)$$

当基函数为高斯函数时, 可如下表示:

$$\begin{aligned} y_{kj}(X_k) &= \sum_{i=1}^I w_{ij} G(|X_k - t_i|) \\ &= \sum_{i=1}^I w_{ij} \exp\left(-\frac{1}{2\sigma_i^2} |X_k - t_i|^2\right) \\ &= \sum_{i=1}^I w_{ij} \exp\left(-\frac{1}{2\sigma_i^2} \sum_{m=1}^M (x_{km} - t_{im})^2\right) \end{aligned} \quad (2)$$

其中:  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}, \dots, t_{iM}]$ , ( $i = 1, 2, \dots, I$ )—高斯函数的中心;  $\sigma_i$ —高斯函数的方差。

RBF 神经网络要学习的参数有 3 个: 基函数的中心、方差和权值。根据径向基函数中心选取方法的不同, RBF 网络有多种学习方法, 其中最常用的 4 种学习方法有<sup>[7]</sup>: 随机选取中心法、自组织选取中心法、有监督选取中心法和正交最小二乘法。本文采用自组织选取中心法, 其显著特点是先在无导师指导下寻找样本空间中的重要模式和特征, 即自组织学习阶段, 这一阶段完成隐层基函数中心与方差的学习; 然后采取有监督方法学习输出权值, 即有监督学习阶段。这种方法避免了前向网络、反馈网络学习过程中调整所有权值系数的方法, 因而具有稳定性高、学习速度快的特点。

### 3 动态 RBF 神经网络

动态 RBF 神经网络是指可以动态扩大样本空间和隐层节点的 RBF 网络。之所以要动态扩大样本空间和隐层节点, 是由两方面的需求决定的, 一是 RBF 神经网络在线运行的要求; 二是原样本空间代表性的要求。在供热负荷预测及发电厂锅炉负荷预测方面, 由于现场实际情况及系统的复杂性, 所选取的训练样本并不能完全代表所有的工况, 因此, 在出现较大样本偏差的情况下, 程序给出的预测值会有较大的预测误差。为了克服神经网络在这方面的缺点, 许多人进行了有益的尝试, 比较通用的做法是保持网络的样本数不变, 而采取新陈代谢的办法, 将新的样本不断地加入, 把旧的样本不断地淘汰。从表面看, 这种办法很可行, 但实际上却将原来网络所学

到的知识逐渐“遗忘”了。显然, 这对于以往所获得的资料数据是一种巨大的浪费, 而且, 也会严重偏离原来的网络特性。为了克服这方面的问题, 本文提出了动态 RBF 神经网络, 并定义了样本差异  $SD$  和样本局部差异  $PSD$  两个参数, 用于对新样本进行有效性判别。同时, 还给出了输入层灵敏度系数, 以实现大差异样本的负荷预测。

对于新样本  $X_{new} = [x_{new1}, x_{new2}, \dots, x_{newm}, \dots, x_{newM}]$ , 样本差异和样本局部差异分别定义如下:

$$SD = [SD_1, SD_2, \dots, SD_k, \dots, SD_N], (k = 1, 2, \dots, N) \quad (3)$$

$$\text{式中: } SD_k = \frac{1}{M} \sum_{m=1}^M \left| \frac{x_{km} - x_{newm}}{x_{newm}} \right|。$$

$$PSD = [PSD_1, PSD_2, \dots, PSD_m, \dots, PSD_M] (m = 1, 2, \dots, M) \quad (4)$$

$$\text{式中: } PSD_m = (x_{km} - x_{newm}) / x_{newm}。$$

对于新样本  $X_{new}$ , 如果满足:

$$\min(SD_1, SD_2, \dots, SD_k, \dots, SD_N) > 0.2 \quad (5)$$

$$\text{或: } \min(|PSD_1|, |PSD_2|, \dots, |PSD_m|, \dots, |PSD_M|) > 0.5 \quad (6)$$

则认为新样本与原样本空间中的样本差异较大, 应把此样本加入原样本空间, 并将新样本  $X_{new}$  加入到初始中心, 重新训练网络。实践证明, 对于新样本的学习往往只涉及到个别隐单元到输出的连接权值的更新, 而绝大部分连接权值并没有发生变化, 因而原来学习的知识得到了保留。需要注意的是, 不等式(5)和式(6)右侧的值需根据经验确定。另外, 如果新样本不满足不等式(6), 则  $SD$  中小于 0.2 的样本数目越多, 说明新样本在样本空间中的相似样本越多。

对于任一样本  $X_k = [x_{k1}, x_{k2}, \dots, x_{km}, \dots, x_{kM}]$  及实际输出  $Y_k = [y_{k1}, y_{k2}, \dots, y_{kj}, \dots, y_{kJ}]$ , 输入层灵敏度系数定义如下:

$$SCIL = \begin{bmatrix} SCIL_{11}, & SCIL_{12}, & \dots, & SCIL_{1j}, & \dots, & SCIL_{1J} \\ SCIL_{21}, & SCIL_{22}, & \dots, & SCIL_{2j}, & \dots, & SCIL_{2J} \\ \vdots & & & & & \\ SCIL_{m1}, & SCIL_{m2}, & \dots, & SCIL_{mj}, & \dots, & SCIL_{mJ} \\ \vdots & & & & & \\ SCIL_{M1}, & SCIL_{M2}, & \dots, & SCIL_{Mj}, & \dots, & SCIL_{MJ} \end{bmatrix} \quad (7)$$

$$\text{式中: } SCIL_{mj} = \hat{\alpha}_{kj} / \hat{\alpha}_{km} (m = 1, 2, \dots, M; j = 1, 2, \dots, J)$$

输入层灵敏度系数的计算可以采用输入层扰动法, 即每次使一个输入单元变化一微小增量  $\hat{\alpha}_{km}$ , 保持其它输入单元不变, 评估输出层单元的变化量

$\hat{\varphi}_{kj}$ , 则灵敏度系数为:

$$SCIL_{mj} = \hat{\varphi}_{kj} / \hat{\alpha}_{km} \quad (8)$$

对于满足不等式(5)或式(6)的新样本, 利用输入层灵敏度系数和样本局部差异预测锅炉负荷:

$$y_{newkj} = (1 + \sum_{m=1}^M SCIL_{mj} PSD_m x_{new m}) y_{kj}, \quad (k = 1, 2, \dots, N) \quad (9)$$

式中:  $y_{kj}$  根据式(3)和式(4)计算得到的  $X_{new}$  的最相似样本。

#### 4 实验结果与算法验证

针对某电厂采集了大量测试数据, 并从中选取 15 个样本, 样本值列于表 1。1~9 号样本组成样本

空间用于训练网络, 其余样本用于检验结果。本文所采用的动态 RBF 神经网络初始选择由 19 个输入神经元, 5 个隐层单元和一个输出单元构成。在进行负荷预测时, 首先要对输入数据进行有效性判断, 如果新样本满足不等式(5)或式(6), 则先利用式(9)预测锅炉负荷, 同时, 把该样本加入到原样本空间中, 并增加原网络的隐层节点重新训练网络, 如果新样本不满足不等式(5)或式(6), 则执行正常预测程序。

在对表 1 中的数据归一化后, 根据其进行样本 10~15 的样本差异和样本局部差异计算, 这里给出了样本差异和样本局部差异大于 0.5 的数目(见表 2 和表 3)。

表 1 用于验证动态 RBF 神经网络模型的锅炉参数

样本	给水温 度/°C	给水压 力/MPa	给水流 量/ $t \cdot h^{-1}$	主汽温 度/°C	主汽压 力/MPa	主汽流 量/ $t \cdot h^{-1}$	过热器减温 水流量/ $t \cdot h^{-1}$	再热器入口 压力/MPa	再热器入 口温度/°C	再热器出口 压力/MPa
1	234.8	15.19	415.9	517	13.7	380.3	3.7	2.3	289.1	2.2
2	234.9	15.36	398.5	518.8	13.8	394.2	3.7	2.3	289.6	2.2
3	235.9	15.06	402.6	520.3	13.7	395.5	3.5	2.3	291.5	2.2
4	236.5	15.08	402.8	524.4	13.8	396.2	3.7	2.2	289.8	2.1
5	237.9	15.09	400.5	528.5	13.7	398.3	3.7	2.3	288.1	2.2
6	235.7	15.05	411.8	535.6	13.7	395.6	3.6	2.2	292.1	2.1
7	236.7	15.28	405.8	532.5	13.7	394.5	3.6	2.2	289.8	2.1
8	235.9	14.89	411.5	524.4	13.8	394.5	3.5	2.3	289.4	2.2
9	236.7	15.07	402.8	527.5	13.7	396.2	3.6	2.3	288.4	2.2
10	235.4	15.05	400.5	530.8	13.8	398.4	3.6	2.2	289.1	2.1
11	237.9	14.95	394.6	514.6	12.6	380.3	3.6	2.3	289.6	2.2
12	235.6	14.89	398.5	518.8	12.8	376.7	3.5	2.2	288.8	2.1
13	236.7	15.15	412.6	518.6	13.7	394.2	3.7	2.3	288.5	2.2
14	225.9	13.22	371.7	509.8	10.7	355.3	2.7	1.9	289.8	2.0
15	227.3	13.42	375.7	511.8	10.8	360.3	2.8	2.0	288.5	2.0

表 1 续 用于验证动态 RBF 神经网络模型的锅炉参数

样本	再热器出 口温度/°C	再热器减温 水流量/ $t \cdot h^{-1}$	氧量 /%	排烟温 度/°C	空预器入 口风温/°C	送风机入口 风量/ $m^3 \cdot h^{-1}$	排粉机累加 转速/ $t \cdot min^{-1}$	连排流 量/ $t \cdot h^{-1}$	低位发热 量/ $kJ \cdot kg^{-1}$	负荷 /MW
1	519.6	13.4	7.4	137	26.7	498 000	305	1.5	20 775	109.5
2	527.4	11.4	7.7	135	27.4	538 725	318	1.4	20 775	112.1
3	521.9	11.5	8.1	138	26.4	543 755	313	1.4	21 650	110.9
4	518.4	12.4	8.2	133	27.5	542 101	310	1.3	21 650	113.6
5	518.2	12.5	7.6	130	27.8	538 743	318	1.4	21 650	117.9
6	526.5	11.9	7.4	137	27.8	552 326	322	1.3	21 650	120.9
7	530	11.2	7.2	136	28.2	530 298	330	1.2	21 650	123.8
8	521.8	11.4	7.4	133	27.5	539 690	320	1.5	19 688	109.8
9	519.8	12.4	7.5	132	27.8	552 226	322	1.3	19 688	112.1
10	522.6	12.5	7.6	135	27.4	530 898	330	1.3	19 688	116.6
11	518.2	10.5	7.3	130	26.4	498 074	289	1.4	19 688	100.2
12	525.7	9.4	7.5	134	27.5	499 696	318	1.5	19 688	105.6
13	520.8	11.9	7.5	137	27.8	542 755	329	1.3	20 775	120.9
14	518.4	6.3	9.4	144	27.4	343 181	265	1.3	20 775	88.7
15	520.4	6.5	9.2	142	27.8	344 287	271	1.3	20 775	90.5

表 2 样本 10~15 的样本差异

	10	11	12	13	14	15
1	0.053	0.046	0.061	0.036	0.242	0.238
2	0.037	0.056	0.055	0.023	0.234	0.232
3	0.049	0.062	0.065	0.034	0.23	0.228
4	0.031	0.076	0.071	0.033	0.233	0.231
5	0.036	0.065	0.074	0.028	0.256	0.252
6	0.031	0.083	0.058	0.024	0.197	0.182
7	0.038	0.083	0.073	0.033	0.246	0.243
8	0.035	0.047	0.039	0.036	0.24	0.234
9	0.019	0.054	0.058	0.024	0.249	0.245

表 3 样本 10~15 的样本局部差异大于 0.5 的数目

	10	11	12	13	14	15
1	0	0	0	0	2	2
2	0	0	0	0	3	3
3	0	0	0	0	2	2
4	0	0	0	0	3	3
5	0	0	0	0	3	3
6	0	0	0	0	1	1
7	0	0	0	0	3	3
8	0	0	0	0	3	3
9	0	0	0	0	2	2

从表 2 可以看出, 样本 10~13 在样本空间中具有很小的样本差异, 其值均小于 0.2, 而样本 14 和 15 在样本空间中则不存在相似样本, 其样本差异只有(14, 6)、(15, 6)分别为 0.197 和 0.182, 其它均大于 0.2。在表 3 中, 样本 10~13 的样本局部差异也没有大于 0.5 的, 而样本 14、15 的局部差异均有大于 0.5 的。这说明, 这两个样本所包含的信息是原样本空间所不具备的, 因此, 应该把这类样本动态加入到原样本空间中, 并增加原网络的隐层节点重新训练, 以丰富原网络的特性。




图 1 应用基本 RBF 神经网络建模的锅炉负荷曲线




图 2 应用基本 RBF 神经网络的锅炉负荷预测结果




图 3 利用 SCIL 和 PSD 的锅炉负荷预测结果




图 4 应用动态 RBF 神经网络的锅炉负荷预测结果

图 1 为应用 RBF 神经网络建模的锅炉负荷曲线。在实际预测过程中, 从图 2 可以看出, 由于样本 10~13 具有很小的样本差异和样本局部差异, 因而预测误差很小, 而样本 14、15 则不然, 因为其样本差

(下转第 602 页)

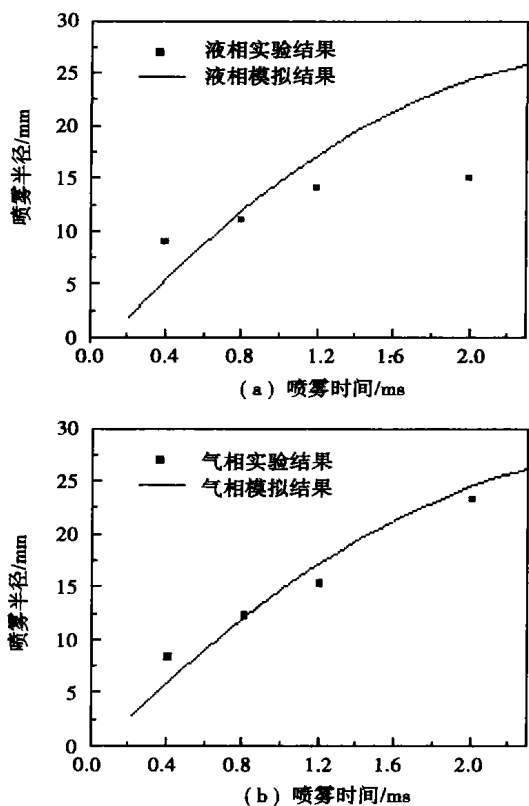


图 5 计算结果与实验结果的比较

参考文献:

[1] LEIDENFROST J G. De aquae communis nonnullis qualitatibus tractat-

us[M]. Gernany: Johann Straube, Duisburg, 1756.

[2] WACHTERS L H J, BONNEH, NOUHS H J VAN. The heat transfer from a hot horizontal plate to sessile water drops in the spheroidal state [J]. *Chem Eng Sci*, 1966, 21(11): 1047-1056.

[3] KARL A, FROHN A. Experimental investigation of interaction processes between droplets and hot walls[J]. *Physics of Fluids*, 2000, 12(4): 785-796.

[4] 李理光, 黄叶舟, 龚允怡. 高压喷雾碰壁的粒度特性研究[J]. *内燃机学报*, 1996, 14(2): 119-126.

[5] SENDA J, KOBAYASHI M, IWASHITA S. Modeling of diesel spray impingement on a flat wall[J]. *Transactions of the SAE*, 1994, 103(3): 1918-1931.

[6] ASHIDA K, TAKAHASHI T, TANAKA T. Spray-wall interaction model considering superheating degree of the wall surface[A]. *Eighth International Conference on Liquid Atomization and Spray Systems* [C]. USA: Pasadena CA, 2000. 1-6.

[7] BAUMEISTERK J, SIMON F F. Leidenfrost temperature-its correlation for liquid metals, cryogenes, hydrocarbons and water[J]. *J Heat Transfer*, 1973, 95(2): 166-173.

[8] NABER J D, REITZ R D. Modeling engine spray/wall impingement [J]. *Transactions of the SAE*, 1989, 97(6): 118-140.

[9] SOMMERFELD M, MUNDO C, TROPEA C. Droplet-wall collisions; experimental studies of the deformation and breakup process[J]. *International Journal of Multiphase Flow*, 1995, 21(2): 151-173.

[10] DEB S, YAO S C. Heat transfer analysis of impacting dilute spray on surface beyond the Leidenfrost temperature[J]. *Proceedings of the ASME National Heat Transfer Conference Pittsburgh Pennsylvania* 1987, 87: 1-8.

[11] TAKEUCHI K, SENDA J. Breakup behavior of fuel jet impinging upon a hot surface[J]. *Internal Combustion Engines*, 1982, 21(7): 9-18.

(渠源 编辑)

(上接第 593 页)

异均大于 0.2, 且局部差异也很大, 因此, 按照预测样本 10~13 的方法进行预测时, 误差较大。而利用输入层灵敏度系数和样本局部差异进行预测, 误差则得到了降低, 如图 3 所示。从图 4 可以看出, 根据本文提出的动态 RBF 网络, 在把样本 14 加入原训练网络并重新训练网络后, 由于样本 15 是样本 14 的相似样本, 因此, 其预测误差明显降低, 得到了与实际负荷比较接近的预测值。

5 结 论

将 RBF 神经网络应用于锅炉负荷预测, 较好地克服了 BP 神经网络收敛速度慢的缺点。同时, 在基本 RBF 神经网络的基础上, 提出了动态 RBF 神经网络模型并进行了相关的数值模拟。通过实验验证表明, 本文提出的样本差异和样本局部差异是两个关键参数, 是动态 RBF 神经网络模型的基础, 利用这两个参数对新样本进行有效地判别, 根据判别结果和输入层灵敏度系数预测锅炉负荷, 可以得到满意的预测结果。这种神经网络模型在锅炉调峰和优

化运行中具有很好的应用前景, 对于锅炉效率、未燃尽碳等预测结果不能在短时间内得到验证的参数的预测也具有显著意义。

参考文献:

[1] HAGAN M T, BEHRS M. The time series approach to short term load forecasting [J]. *IEEE Trans on Power Systems*, 1987, 2(3): 785-791.

[2] PAPALEXOPOULOS A D, HESTERBERG T C. A regression-based approach to short term system load forecasting [J]. *IEEE Trans on Power Systems*, 1990, 5(4): 1535-1544.

[3] MOGHAM I, RAHMAN S. Analysis and evaluation of five short term load forecasting techniques [J]. *IEEE Trans on Power Systems*, 1989, 4(4): 1484-1491.

[4] 缪 力, 邢温航. 人工神经网络在电力负荷预测上的应用[J]. *信息技术*, 2000, 3(1): 62-63.

[5] 杨洪明, 白培林. 基于遗传算法的人工神经网络负荷预测模型 [J]. *湖南电力*, 2000, 20(1): 6-8.

[6] 董景荣. 基于小波网络的电力系统短期负荷预报研究 [J]. *预测*, 2000, 4(4): 66-69.

[7] 高 隼. 人工神经网络原理及仿真实例 [M]. 北京: 机械工业出版社, 2005.

(渠源 编辑)

the system error should involve the decomposition of sulfate and release of water of crystallization and hydration from mineral constituents. When using this method to check the performance and efficiency of a CFB boiler unit, one shall take into account the effect of these factors. On the basis of TGA-FTIR experiments, presented is a new TGA method for measuring the carbon content of fly ash of a CFB boiler, which can avoid the system error caused by the decomposition of sulfate and the release of water of crystallization and hydration from mineral constituents. In the meantime, the system error resulting from high-temperature cracking of newly produced carbon-containing organic matter can be negligible. The result thus measured further approximates to the actual carbon content of the fly ash of the CFB boiler. **Key words:** system error, loss-on-ignition, circulating fluidized bed, fly ash

基于动态 RBF 神经网络的锅炉短期负荷预测研究 = **An Investigation Concerning the Prediction of Short-term Loads of Boilers based on a Dynamic RBF (Radical Based Function) Neural Network** [刊, 汉] / DAI Wei-bao, ZOU Ping-hua (College of Municipal Environmental Engineering under Harbin Institute of Technology, Harbin, China, Post Code: 150001), FENG Ming-hua, WANG Yu-shan (Heilongjiang Provincial Academy of Electric Power Sciences, Harbin, China, Post Code: 150030) // Journal of Engineering for Thermal Energy & Power. — 2006, 21(6). — 590 ~ 593, 602

The thermal inertia of boilers can lead to the relative lagging of a whole thermal system and affect the peak-shaving and optimization operation of the system. Hence, a prediction of the short-term loads of boilers based on the system parameters has become especially important. On the basis of a RBF neural network, a dynamic one is presented and the definition of two related parameters, i. e. specimen variance and specimen local variance, given to conduct an effectiveness discrimination for a new specimen. The actual operational data of a power plant have been used to verify the soundness of the established model. Meanwhile, an input-layer sensitivity factor is presented to predict the load of a large variance specimen. Boiler future loads were predicted by using the dynamic RBF neural network and in the meantime the predicted results were compared with the experimental ones. The results of the comparison indicate that the above network has a strong adaptability and can accurately predict boiler loads, presaging a bright prospect for engineering applications. **Key words:** dynamic RBF (radial based function), load prediction, specimen variance, specimen local variance, input layer sensitivity factor

一种基于自适应小波变换的火焰检测方法的研究 = **An Investigation of the Flame Detection Method based on Self-adaptive Wavelet Conversion** [刊, 汉] / AO Li-min, LI Jian-hua, SONG Xuan, et al (College of Information Engineering under the Northeast University of Electric Power, Jilin, China, Post Code: 132012) // Journal of Engineering for Thermal Energy & Power. — 2006, 21(6). — 594 ~ 597

In view of the features specific to present-day furnace flame detection systems, such as great difficulty in extracting signal characteristics, low signal-noise ratio and difficulty in making an accurate decision, a judgement method was proposed based on wavelet conversion in combination with a BP neural network. This has been undertaken through an acquisition and analysis of experimental data of pulverized coal combustion in a furnace. Under the above method the collected noise-containing signals will undergo a multi-dimensional wavelet decomposition and characteristics extraction. Thereafter, the signals are subject to a soft threshold value de-noising treatment with the pretreated information serving as a training input to the neural network. A furnace-flame combustion experiment at a power plant has proved that the time-frequency localized analytic method can improve the signal-noise ratio and more effectively identify the combustion state of a flame and is assessed as possessing a wide-ranging practical value. **Key words:** flame detection, wavelet resolution, extraction of characteristics, threshold value, BP neural network

油雾碰撞高温壁面的油滴分裂及与热壁间换热研究 = **A Study of Oil Droplet Fracture during the Impingement of Oil Mist on a High-temperature Wall Surface and the Heat Exchange of the Oil Droplets with the High-temperature Wall** [刊, 汉] / ZHAO Zhi-guo, XIE Mao-zhao, WANG Cui-hua (College of Energy and Power Engineering under the Dalian University of Sciences and Technology, Dalian, China, Post Code: 116024) // Journal of Engineering