DOI:10.16146/j.cnki.rndlgc.2014.03.013

第 29 卷第 3 期 热 能 动 力 工 程 Vol. 29, No. 3
2014 年 5 月 JOURNAL OF ENGINEERING FOR THERMAL ENERGY AND POWER May., 2014

文章编号: 1001 - 2060(2014) 03 - 0279 - 05

燃煤锅炉 NO_x 排放浓度的智能预报

尹凌霄, 王明春, 尚 强
(东南大学 能源与环境学院, 江苏 南京 210096)

摘 要: 在热态试验数据的基础上, 分别应用 BP(神经网络)和 SVM(支持向量机)回归算法建立了燃煤机锅炉 NO_x 排放特性模型, 并验证了模型的准确性。结果表明, BP 网络模型对检验样本的最大预测误差、最小预测误差和均方差分别为 4.263%、0.556% 和 2.2133%, 支持向量机模型对检验样本的最大预测误差、最小预测误差和均方差分别为 2.121%、0.091% 和 0.4549%。两种智能技术都能对锅炉在不同工况下的 NO_x 排放做出较为准确的预报, 但支持向量机在泛化能力、收敛速度、最优性等方面明显优于神经网络。

关 键 词: NO_x; 锅炉; 神经网络; 支持向量机

中图分类号: TK229.6+6 **文献标识码**: A

引 言

锅炉 NO_x 的排放特性是非常复杂的, 具有很强的非线性和多元性。难以采用简单的公式对 NO_x 的排放进行估算, 往往需要采用实炉测试的方法加以确定, 并通过试验结果摸索降低 NO_x 的方法。但此种方法费时费力, 且 NO_x 排放的影响因素耦合性强, 导致数据分析困难, 难以建立推广性能较好的计算模型, 不利于燃煤锅炉通过燃烧调整降低 NO_x 排放。

人工智能技术的发展及广泛应用为锅炉 NO_x 排放建模提供了可能。智能建模主要利用锅炉运行数据及燃烧试验数据, 将燃烧过程视为一个“黑箱”, 只关注输入、输出参数的关系, 建立和测试针对机组的数学模型。

本研究在热态试验数据的基础上, 分别应用神经网络和支持向量机算法建立了燃煤锅炉 NO_x 排放特性模型, 并对模型进行了校验。研究结果表明, 智能模型能够根据燃煤特性及各种操作参数对 NO_x 的排放做出较为准确的预报, 此外, 相比神经网络, 支持向量机在泛化能力、收敛速度、最优性等方面都体现明显的优越性。

收稿日期: 2013 - 09 - 05; **修订日期**: 2013 - 12 - 02

作者简介: 尹凌霄(1989 -), 男, 江苏宿迁人, 东南大学硕士研究生.

1 BP 神经网络学习算法

BP 网络是从输入到输出的高度非线性映射, 即 $F: R_n \rightarrow R_m$, $f(x) = Y_0$ 对于样本集合: 输入 $x_i(R_n)$ 和输出 $y_i(R_m)$, 可以认为存在某一映射 g, 使 $g(x_i) = y_i$, $(i = 1, 2, \cdots, p)$。先要求出映射 f, 在某种意义下 f 是 g 的最佳逼近。Hecht - Nislsen 证明了如下的 Kolmogorov 定理: 给定任意连续函数 f: $U \rightarrow R$, 这里 $U \in [0,1]$, f 可以精确地用一个 3 层前馈网络实现。图 1 给出了一个 3 层 BP 网络结构, 其中 $[x]$、$[y]$ 分别表示输入、输出参数, W_{ij} 表示输入层与隐含层的权值, W_{jk} 表示隐含层与输出层的权值[1]。

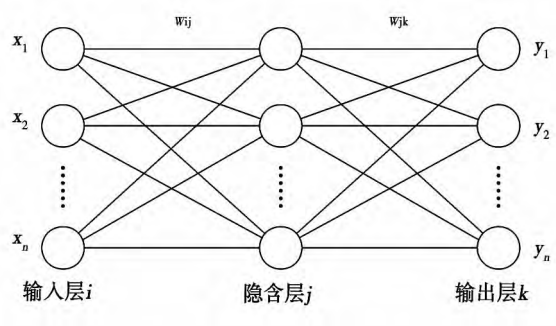

图 1 3 层 BP 网络结构

Fig. 1 Three-hierarchy BP network structure

2 支持向量机回归算法

回归问题为: 由输入输出函数集 (x_i, y_i) $(i = 1, \cdots, m)$, 求取输入和输出之间的关系: $f(x) = w \cdot x + b$。在支持向量回归中, 将输入向量映射到 l 维特征空间, 然后在特征空间中构造优化超平面: $f(x) = W^T x g(x) + b$。其中, W 是 l 维权重向量, $g(x)$ 是将 x 映射到特征空间的映射函数, b 为偏置项[2-3]。设

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

$\varphi(x)$ 为映射用的非线性函数，则 $K(x_i,x_j)=\varphi(x_i)\cdot\varphi(x_j)$，是映射函数的点积，称为核函数。

引入精度 ε 和非负松弛变量 ξ_i 和 ξ_i^*，可得到线性回归估计的优化问题：

$$\min R(w,\xi_i,\xi_i^*)=\frac{1}{2}\|w\|^2+C\sum_{i=1}^{m}(\xi_i+\xi_i^*) \tag{1}$$

约束条件为：

$$\begin{cases} y_i-w\cdot x_i-b\leqslant\varepsilon+\xi_i \\ w\cdot x_i+b\leqslant\varepsilon+\xi_i^* \quad i=1,\cdots,m \\ \xi_i,\xi_i^*\geqslant 0 \end{cases} \tag{2}$$

其中，$\frac{1}{2}\|w\|^2$ 为结构风险；$C\sum_{i=1}^{m}(\xi_i+\xi_i^*)$ 为经验风险；常数 $C>0$ 为惩罚系数。

3 实例分析

3.1 设备概括及试验样本的获取

利用文献[5]提供的现场试验工况数据，分别建立 NO_x 排放特性的响应模型。试验锅炉蒸发量为 1 160 t/h，主蒸汽温度为 540 ℃，压力为 16.82 MPa，配用 350 MW 的凝汽式发电机组单元布置。锅炉采用直吹式磨煤系统，燃烧器使用燃料为煤、高炉煤气、焦炉煤气混烧，BFG(高炉煤气)和 COG(焦炉煤气)的最大混烧比为 65%，四角布置，切向燃烧。试验数据共 43 组，全负荷 29 组，90% 负荷 2 组，80% 负荷 7 组，70% 负荷 3 组，60% 负荷 2 组。现场试验数据如表 1 和表 2 所示。

表 1 现场试验工况数据表(1)

Tab. 1 A list of the operating conditions and data obtained on site during the test(1)

工况	负荷 /kW	BFG /$m^3\cdot h^{-1}$	COG /$m^3\cdot h^{-1}$	煤粉 /$t\cdot h^{-1}$	煤种特性					排烟温度/℃	氧量 /%
					W_{ar}/%	V_{ar}/%	C_{ar}/%	A_{ar}/%	Q/kJ·kg^{-1}		
1	347.5	0.0	0.00	136.49	10.1	25.98	53.42	10.5	25 157	152.59	4.00
2	347.4	0.0	0.00	136.39	10.1	25.98	53.42	10.5	25 157	135.60	4.00
3	346.6	0.0	0.00	135.53	10.1	25.98	53.42	10.5	25 157	153.50	4.00
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
36	349.8	343.3	18.76	85.00	10.1	25.98	53.42	10.5	25 157	178.90	4.09
37	350.5	343.3	18.94	79.80	10.1	25.98	53.42	10.5	25 157	180.57	4.02
38	344.3	0.0	0.00	137.94	10.1	25.98	53.42	10.5	25 157	178.90	3.94
39	277.3	0.0	0.00	109.36	10.1	25.98	53.42	10.5	25 157	130.30	4.00
40	347.4	150.0	0.00	137.94	10.1	25.98	53.42	10.5	25 157	164.70	4.00
41	352.3	253.1	0.00	108.70	10.1	25.98	53.42	10.5	25 157	178.60	3.84
42	349.2	250.3	0.00	109.30	10.1	25.98	53.42	10.5	25 157	186.30	4.04
43	350.2	241.3	29.36	74.90	10.1	25.98	53.42	10.5	25 157	179.90	3.97

3.2 模型的输入变量的选取

模型的输入变量选取如下：采用锅炉负荷、入炉总煤量、BFG 投入量和 COG 投入量描述锅炉负荷对 NO_x 的影响；5 层磨煤机给煤量和 5 层一次风开度，用以描述风煤量沿炉高分配对炉内燃烧的影响；二次风各层联动，以描述二次风配风方式对燃烧的影响；取炉膛出口烟气含氧量平均值作为 1 个输入参数，描述燃烧氧量的影响；取排烟温度描述尾部温度对 NO_x 的影响；煤种特性取低位发热量、挥发分、含碳量、灰分和水分共 5 个参数，以描述煤种特性的影响；各层燃烧器摆角联动，对应 1 个燃烧器摆角；共有 23 个输入参数。以上各参数均可由电厂 DCS 中获得。

3.3 预测模型的建立与比较

在试验工况数据的基础上分别通过 BP 神经网络和支持向量回归机算法建立 NO_x 预测模型。试验工况数据共 43 组，取前 35 组作为训练样本，后 8 组作为检验样本。

BP 神经网络选用 23 个输入节点，1 个输出节点，通过 35 组样本数据来训练神经网络，采用“试

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

错法”确定隐层节点数为 20，根据经验公式(3) 得出学习速率为 0.1，具体公式如下

$$\eta = 1\sqrt{\eta e} \tag{3}$$

式中：ηe—隐层节点数。

传递函数为 S 传递函数，训练函数为基于 Levenbe rg – Marquardt 非线性最小二乘方法的 ‘trainlm (训练函数)’，设置当系统的均方差小于 0.000 001 时训练结束。采用以上方法使人工神经网络通过学习获得正确的输入—输出响应模型，为验证模型的正确性，利用训练好的神经网络模型对检验样本进行评价检验。BP 网络训练过程如图 2 所示，神经网络模型对训练样本和检验样本的真实值与预测值的对比如图 3 所示，通过图 2 可以发现神经网络可以对 NO_x 的排放做出比较精确的预测。

表 2　现场试验工况数据表(2)

Tab. 2 A list of the operating conditions and data obtained on site during the test(2)

工况	各层煤粉流量/t·h^{-1}					各层一次开度风/%					二次风	燃烧器	NO_x
	G	H	I	H	K	G	H	I	H	K	开度/%	摆角/%	/mg·m^{-3}
1	27.29	27.27	27.38	27.51	27.04	76.88	75.99	76.51	76.58	75.76	27.29	20.18	374.8
2	27.28	27.26	27.34	27.47	27.04	76.13	75.94	77.09	75.76	75.76	27.28	25.61	434.2
3	27.21	27.17	27.25	26.96	26.94	76.37	76.14	76.17	76.77	75.80	27.21	30.47	430.7
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
36	21.50	21.80	22.10	19.60	0.00	72.52	71.41	70.75	70.35	11.19	21.50	22.00	314.5
37	20.40	20.50	20.70	18.20	0.00	72.52	71.41	70.75	70.35	11.19	20.40	22.00	315.4
38	27.52	27.60	27.80	27.60	27.39	76.83	77.09	78.02	76.76	76.34	100.00	20.56	534.0
39	27.35	27.34	27.45	27.20	0.00	75.88	76.50	77.18	76.70	12.39	60.00	19.99	539.5
40	23.08	23.01	23.16	23.10	22.82	72.12	71.63	71.12	71.43	71.39	75.00	19.30	441.6
41	19.60	24.40	24.30	24.40	16.00	69.13	72.25	71.94	70.97	67.09	60.00	221.60	311.8
42	23.40	23.50	23.60	23.50	15.30	72.94	70.26	69.81	69.74	67.23	73.00	20.30	320.0
43	19.70	19.80	20.00	15.40	0.00	70.44	70.26	70.50	69.01	10.77	56.00	22.10	298.0

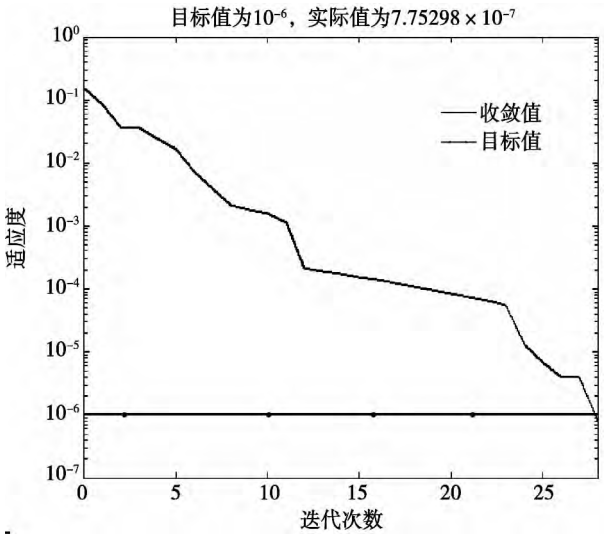

图 2　BP 网络的训练过程

Fig. 2 BP network training process

采用支持向量机建模时，参考文献 [4] 选择径向基函数 $\exp(\sigma x|x_i - x_j|^2)$ 为核函数。此时，模型的学习能力和泛化能力主要取决于支持向量机结构参数的惩罚系数 C 和核参数 σ 的取值。为找到合适的参数组合，利用 K – fold 交叉验证方法[6]，通过不断调整各个参数的值进行循环搜索优化以获得最佳参数组合[6]。其中 $K=5$，具体步骤如下：

(1) 设定模型参数的寻优范围，设定惩罚系数 C 和核参数 σ 分别为(0,800)，(0,30)；

(2) 初始化模型的各个参数；

(3) 在现有参数组合下，把 1 – 35 工况分为 5 组，每 5 个工况分为 1 组，顺次划分。以第一组作为验证样本，其它 4 组为训练样本，然后计算测试集的 MSE(推广误差)。计算公式如下：

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{4}$$

式中：y_i，$\hat{y}_i$—验证样本的实际值和预测值；n—验证样本的个数。

(4) 按上述方法循环操作直到以第 5 组作为测试工况，然后计算出 5 次推广误差的平均值。

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

(5) 不断改变参数的组合，直到 5 次推广误差的平均值为最小，对应的参数为最佳参数组合。

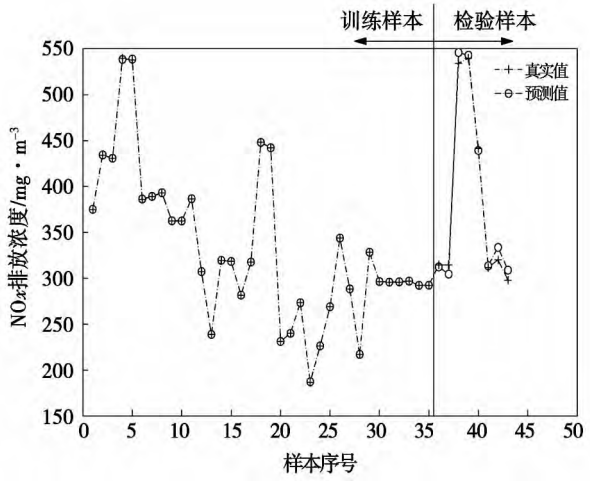

图 3 BP 神经网络模型预测值与样本真实值比较

Fig. 3 Comparison of the real value obtained by using the sample with the value predicted by using the BP (back propagation) neural network model

按照上述的方法，通过粒子群算法寻优得到的最佳参数组合为 $C = 227.6325$，$\sigma = 6.3725$，预测模型的建模流程图如图 5 所示。支持向量机模型对 NO_x 排放量的预测与真实值的比较如图 4 所示。由图 4 可以发现模型的训练样本的预测与真实值几乎一致，对检验样本的预测偏差也较小，足以说明支持向量机能够对 NO_x 排放做出精确的预测，具有较好的泛化能力。

表 3 给出了神经网络和支持向量机对验证样本的预测比较，BP 模型和 SVM 模型的均方根误差分别为 2.213 3% 和 0.454 9%，最大预测误差分别为 4.263% 和 2.121%，说明用 SVM 模型预测 NO_x 的排放精确程度较高。

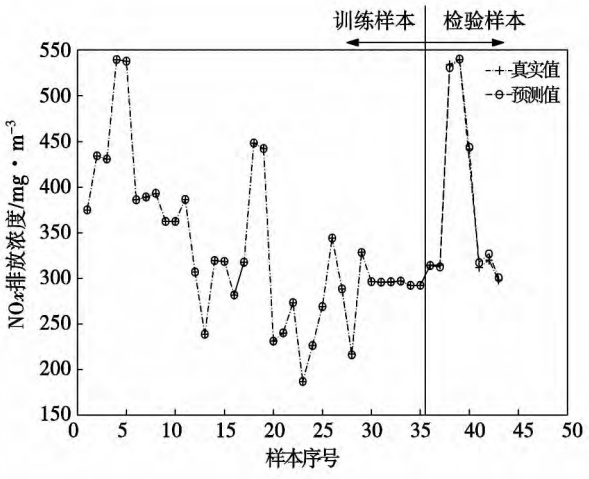

图 4 支持向量机模型预测值与样本真实值比较

Fig. 4 Comparison of the real value obtained by using the sample with the value predicted by using the support vector machine model

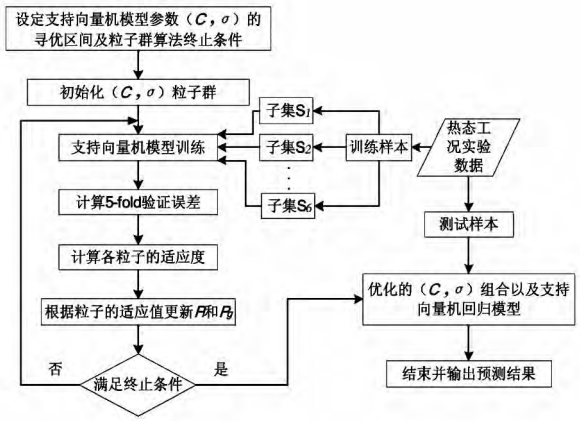

图 5 支持向量机预测模型建模流程图

Fig. 5 Flow chart for modeling by using the support vector machine prediction model

表 3 BP 模型和 SVM 模型的预测比较

Tab. 3 Comparison of the values predicted by using the BP network model and the support vector machine model

工况	36	37	38	39	40	41	42	43	均方差
真实值/mg·m^{-3}	314.500	315.400	534.000	539.500	441.600	311.800	320.000	298.000	
BP 预测值	312.236	304.467	545.611	542.785	439.143	313.580	333.642	308.861	
相对误差/%	0.720	3.467	2.174	0.609	0.556	0.571	4.263	3.644	2.2133
SVM 预测值	314.000	312.560	530.687	539.990	443.586	317.165	326.787	300.588	
相对误差/%	0.159	0.900	0.620	0.091	0.450	1.720	2.121	0.868	0.4549

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

此外使用神经网络建模由于其可重复性差，每次训练过程得到的权值和阈值可能不同，进而导致每次训练后的预测结果不同，甚至会出现较大的偏差。同时此次试验模型的训练时间为 16.48 s，耗时较长不适于在线优化控制。相比而言 SVM 模型每次预测的值都比较稳定，再加上 SVM 训练时间较快，此次试验模型训练时间仅为 0.98 s，所以更适用于在线的优化控制。

4　结　论

(1) 神经网络和支持向量机作为典型的智能方法，在复杂系统输入输出关系的建模上体现了良好的优越性。采用人工智能方法利用锅炉燃烧试验数据，将燃烧过程视为一个“黑箱”，只关注输入和输出参数的关系，建立了 NO_x 排放特性的相应模型，通过试验值和模型计算值的比较，证实了人工智能建模合理性。

(2) 使用 BP 神经网络建模，网络的层数、拓扑结构和学习速率等因素对模型的训练时间、泛化能力等有着重要的影响，本研究采用 3 层 BP 网络，通过“试错法”确定隐层单元数，根据经验公式确定学习速率，结果表明，对检验样本的最大预测误差为 4.263%，最小预测误差为 0.556%，均方差为 2.213 3%，可以实现较为准确的预测。

(3) 使用支持向量机建模，模型的学习能力和泛化能力取决于支持向量机的惩罚系数 C 和核参数 σ 的取值。本例采用了 K－fold 交叉验证方法，K 取 5，循环搜索寻优模型的结构参数，找到最优的参数组合，在最优参数组合下，模型对检验样本的最大预测误差、最小预测误差和均方差分别为 2.121%、0.091% 和 0.4549%，比 BP 神经网络的预测更加准确。此外，与 BP 网络模型相比，支持向量机在泛化能力、收敛速度、最优性等方面体现了明显的优越性，更适用于在线的优化控制。

(4) 人工智能建模的意义在于建立的模型可以根据输入参数准确地预报 NO_x 的排放浓度，同时如果结合全局寻优算法，可以寻找出最优的操作参数，以便于根据需要降低 NO_x 的排放浓度。

参考文献：

[1] 周　昊，茅建波，池作和，等. 燃煤锅炉低氮氧化物燃烧特性的神经网络预报 [J]. 环境科学，2002，23(3)：18－22.
ZHOU Hao，MAO Jian-bo，CHI Zuo-he，et al. Prediction of the low NOx combustion characteristics of a coal-fired boiler by using a neural network [J]. Environmental Science，2002，23(2)：18－22.

[2] 方瑞明. 支持向量机理论及其应用分析 [M]. 北京：中国电力出版社，2007.
FANG Rui-ming. Theory of the support vector machine and analysis of its applications [M]. Beijing：China Electric Power Press，2007.

[3] 白　鹏，张喜斌，张　斌，等. 支持向量机理论及工程应用实例 [M]. 西安：西安电子科技大学出版社，2008.
BAI Peng，ZHANG Xi-bin，ZHANG Bin，et al. Theory of the support vector machine and examples of its applications in engineering projects [M]. Xi´an：Xi´an University of Electronic Sciences and Technology Press，2008.

[4] Keerthi K，Lin C J. Asymptotic behaviors of support vector machines with Gaussian kernel [J]. Neural Computation，2003 15(3)，1667－1689.

[5] Cao L J，Chua K S，Chong W K，et al. A comparison of PCA，KPCA and ICA for dimensionality reduction in support vector machine [J]. Neural Compute，2003(55)：321－336.

[6] 周海珠. 350 MW 电站锅炉燃烧优化技术研究 [D]. 上海：同济大学机械工程学院，2008.
ZHOU Hai-zhu. Study of the technologies for optimizing the combustion of a 350 MW utility bolier [D]. Shanghai：College of mechanical engineering under Tongji University，2008.

（陈　滨　编辑）

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

ted and Mixed with Water on the Thermal Efficiency of a Boiler [刊,汉] ZHANG Lu,ZHU Yi-min,LI Tie,TANG Xiao-jia,ZHANG Hong-peng (Environmental Pollution Treatment Research Institute,Dalian Maritime University,Dalian,China,Post Code: 116026) //Journal of Engineering for Thermal Energy & Power. - 2014,29(3). -274 -278

A self-made mechanical micro agitation fuel oil water-dilution-mixing device was adopted to prepare fuel oil mixed with water in various water drop particle diameters (9.36 μm,11.27 μm,14.49 μm and 20.55 μm) and such fuel oil was applied in a thermally-injected boiler in an oil field for an on-line test. The test results show that the thermal efficiency of the boiler burning the fuel oil diluted and mixed with water prepared by using the mechanical agitation method can be improved remarkably when compared with that burning the fuel oil not diluted and mixed with water and when the water drop particle diameter of the fuel oil mixed with water is 9.36 μm,the thermal efficiency of the boiler will be highest. In such a case,the direct balance efficiency of the boiler will be 89.73% and the oil saving rate will be 4.49%. **Key words:** mechanical micro agitation,water drop particle diameter,fuel oil diluted and mixed with water,thermal efficiency of a boiler,oil saving

燃煤锅炉 NO_x 排放浓度的智能预报 = Intelligent Prediction of the NO*x* Emissions Concentration of a Coal-fired Boiler [刊,汉] YIN Ling-xiao,WANG Ming-chun,SHANG Qiang (College of Energy Source and Environment,Nanjing,China,Post Code: 210096) //Journal of Engineering for Thermal Energy & Power. - 2014,29(3). -279 -283

On the basis of the hot state test data,the BP neural network and supporting vector machine regression algorithms were used respectively to establish models controlling the NO_x emissions characteristics of a coal-fired boiler and verify the accuracy of the models. The research results show that the maximum prediction error,minimum prediction error and mean variance of the specimen by using the BP network model are 4.263%,0.556% and 2.2133% respectively and those by using the supporting vector machine model are 2.121%,0.091% and 0.4549% respectively. Both intelligent technologies can make a relatively accurate prediction of NO_x emissions under various operating conditions of the boiler,however,the supporting vector machine model is obviously superior to the neural network model in terms of general-purpose capability,converging speed and optimization etc. **Key words:** NO_x,boiler,neural network,supporting vector machine

磁场强度对层流预混火焰燃烧过程中 NO_x 生成特性的影响 = Influence of the Intensity of a Magnetic Field on the NO_x Production Characteristics During the Laminar Flow Premixed Flame Combustion [刊,汉] CHEN Wei-peng,ZHU Bing-sen,LI Bao-wei,WU Wen-fei (Inner Mongolia University of Science and Technology,

?1994-2018 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net