

# 基于约束支持向量回归的电站锅炉燃烧优化建模

闫水保,冯 灿,齐继鹏,钱亿博

(郑州大学 机械与动力工程学院,河南 郑州 450001)

**摘 要:**为建立一个有效的电站锅炉效率与 $\text{NO}_x$ 排放浓度预测模型,在最小二乘支持向量回归算法(Least Squares Support Vector Regression, LSSVR)基础上进行改进,提出了约束支持向量回归算法(Constraint Support Vector Regression, CSVr),通过优化支持向量的选择策略,来增强算法泛化能力和对不良数据的抵御能力。初始数据经主成分分析(Principal Component Analysis, PCA)后,输入基于CSVr算法的锅炉燃烧模型进行训练,并将建模结果与LSSVR算法和BP神经网络算法进行了比较。结果表明:使用PCA对数据预处理后,输入变量维数由五维降到三维,简化了模型结构,同时又保留了输入数据的主要特征。在相当的平均预测误差水平上,CSVr算法选用支持向量数目分别只有83个和117个,远少于LSSVR算法选用的900个;CSVr的最大预测相对误差只有3%,远低于LSSVR的25.8%,BP算法介于两者之间。

**关 键 词:**锅炉效率; $\text{NO}_x$ 排放浓度;主元分析;支持向量回归;约束最优化

中图分类号:TM621.2 文献标识码:A DOI:10.16146/j.cnki.rndlge.2021.11.018

[引用本文格式]闫水保,冯 灿,齐继鹏,等.基于约束支持向量回归的电站锅炉燃烧优化建模[J].热能动力工程,2021,36(11):126-132. YAN Shui-bao, FENG Can, QI Ji-peng, et al. Combustion optimization modeling of boiler in power plant based on constrain support vector regression[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(11):126-132.

## Combustion Optimization Modeling of Boiler in Power Plant based on Constrain Support Vector Regression

YAN Shui-bao, FENG Can, QI Ji-peng, QIAN Yi-bo

(School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou, China, Post Code: 450001)

**Abstract:** In order to build an effective prediction model for power plant boiler efficiency and  $\text{NO}_x$  emission concentration, based on the improved least squares support vector regression (LSSVR) algorithm, the constraint support vector regression (CSVr) algorithm was proposed to strengthen the algorithm generalization ability and the resistance ability to bad data by optimizing the selection strategy of support vector. After the initial data was subjected to principal component analysis (PCA), it was input into the boiler combustion model based on CSVr algorithm for training, and the modeling results were compared with the LSSVR algorithm and the BP neural network algorithm. The results show that the dimension of input variables is reduced from 5 to 3 after data preprocessing by PCA, which simplifies the model structure and retains the main characteristics of input data. At a comparable level of average prediction error, the numbers of support vectors used by the CSVr algorithm are only 83 and 117 respectively, which are both far less than the number of 900 used by the LSSVR algorithm. The maximum prediction relative error of CSVr is only 3%, which is much lower than 25.8% of LSSVR, and the BP algorithm is somewhere in between.

**Key words:** boiler efficiency,  $\text{NO}_x$  emission concentration, principal component analysis, support vector regression, constrain optimization

## 引 言

锅炉燃烧是一个复杂过程,难以完全依靠机理方法建立优化数学模型。在机组运行过程中,监测系统产生大量的运行数据,这些数据能反映出燃烧过程的一些重要特征,提取这些特征指标,有助于提升优化过程建模的品质。

近年来,众多学者对锅炉燃烧优化的数据建模进行了大量研究。常见的方法有神经网络、支持向量机、最小二乘支持向量回归等<sup>[1]</sup>。文献[2-7]分别建立了基于不同类型神经网络技术的锅炉燃烧预测模型。神经网络模型基于经验风险最小化原则,依赖大数据样本,易陷入局部最优,训练速度慢。最小二乘支持向量回归(LSSVR)是支持向量机的改进方法,基于结构风险最小化原则,对小样本有较好的学习效果,不易出现过学习现象<sup>[8]</sup>。文献[9-13]使用 LSSVR 方法对锅炉效率、NO<sub>x</sub> 排放浓度和炉膛床温分别建立了有效的预测模型。但在样本过多时,LSSVR 算法会出现算法稀疏性差,矩阵求逆计算量大,对不良样本敏感等支持向量过多的问题。

本文在改进 LSSVR 算法基础上,提出了约束支持向量回归(CSVR)算法。通过增加约束条件来强化支持向量的选择,减少支持向量规模和计算量,提高算法泛化能力与鲁棒性。用 CSVR 算法建立锅炉效率及 NO<sub>x</sub> 排放浓度预测模型,提高模型的泛化能力和抵御不良数据的能力,并与 LSSVR 和 BP 神经网络方法进行比较。

## 1 CSVR 算法的建立

### 1.1 对 LSSVR 算法的改进

LSSVR 算法输入给定样本集  $\{(x_i, y_i), i = 1, 2, \dots, l\}$  ( $x_i \in R^n$  是第  $i$  个样本输入值矢量,  $y_i \in R$  为其对应输出值),变量  $y$  对输入变量  $x$  的依赖关系是由式(1)描述问题的解:

$$\begin{cases} \min J(\mathbf{w}, \boldsymbol{\xi}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{c}{2} \boldsymbol{\xi}^T \boldsymbol{\xi} \\ y = \varphi(\mathbf{X}) \mathbf{w} + \mathbf{I}b + \boldsymbol{\xi} \end{cases} \quad (1)$$

式中:  $\mathbf{X} = [x_1, x_2, \dots, x_l]^T$ —输入矢量,  $\boldsymbol{\xi} = [\xi_1,$

$\xi_2, \dots, \xi_l]^T$ —误差矢量,  $\mathbf{y} = [y_1, y_2, \dots, y_l]^T$ —输出矢量;  $\mathbf{w} = [w_1, w_2, \dots, w_l]^T$ —待求系数矢量;  $\mathbf{I} = [1, 1, \dots, 1]^T$ —各分量为 1 的矢量;  $b$ —待求量;  $c$ —权重因子;  $\varphi(\cdot)$ —标量算子。

若定义  $\tilde{\mathbf{y}} = \mathbf{y} - \mathbf{I}b$ ,即以  $b$  作为变量  $\mathbf{y}$  的计量起点,该优化问题用 Lagrange 法转化为:

$$\max_a \min_w L(\mathbf{w}, \boldsymbol{\xi}, a) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{c}{2} \boldsymbol{\xi}^T \boldsymbol{\xi} - a^T (\varphi(\mathbf{X}) \cdot \mathbf{w} + \boldsymbol{\xi} - \tilde{\mathbf{y}}) \quad (2)$$

式中:  $L$ —Lagrange 函数;  $\mathbf{a}$ —Lagrange 乘子矢量。Lagrange 函数分别对  $\mathbf{w}$  和  $\boldsymbol{\xi}$  变量求导并令其等于零,即  $\nabla_w L = \nabla_{\boldsymbol{\xi}} L = 0$ ,解出  $\mathbf{w}$  和  $\boldsymbol{\xi}$  之后代入式(2),消去  $\mathbf{w}$  和  $\boldsymbol{\xi}$  之后的 Lagrange 函数记为  $H(\mathbf{a})$ ,即:

$$\min H(\mathbf{a}) = \frac{1}{2} \mathbf{a}^T \boldsymbol{\Omega} \mathbf{a} - \tilde{\mathbf{y}}^T \mathbf{a} \quad (3)$$

式中:  $\boldsymbol{\Omega} = \mathbf{K} + \frac{1}{c} \mathbf{E}$ ,  $\mathbf{E}$ —单位矩阵;  $\mathbf{K} = [K_{i,j}]$ ,  $K_{i,j}$ —核函数。核函数取为径向基函数<sup>[1]</sup>,  $K_{i,j} = K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$ 。

式(3)是  $\mathbf{a}$  的二次函数,  $\tilde{\mathbf{y}}$  是  $\mathbf{a}$  的一次项的系数,  $\tilde{\mathbf{y}}$  的各分量绝对值越小,所得到优化问题的解中,  $\mathbf{a}$  各个分量的绝对值越小。为了使决策函数的系数  $\mathbf{a}$  中非零分量的绝对值不至于过大,可以通过调整参数  $b$ ,使  $\tilde{\mathbf{y}}$  在一定的准则下为最小,即:

$$\begin{cases} \min \frac{1}{2} \tilde{\mathbf{y}}^T \tilde{\mathbf{y}} \\ \mathbf{y} = \mathbf{I}b + \tilde{\mathbf{y}} \end{cases} \quad (4)$$

该问题的最小二乘估计值为  $b = (\mathbf{I}^T \mathbf{I})^{-1} \mathbf{I}^T \mathbf{y} = \bar{y}$ ,在求解(3)时,取  $\tilde{\mathbf{y}} = \mathbf{y} - \mathbf{I}\bar{y}$ 。

令  $\nabla_a H(\mathbf{a}) = \boldsymbol{\Omega} \mathbf{a} - \tilde{\mathbf{y}} = \mathbf{0}$ ,可得:

$$\mathbf{a} = \boldsymbol{\Omega}^{-1} \tilde{\mathbf{y}} \quad (5)$$

此时决策函数为:

$$f(\mathbf{x}) = \sum_{i=1}^l a_i K(\mathbf{x}, \mathbf{x}_i) + \bar{y} \quad (6)$$

式中:  $K(\mathbf{x}, \mathbf{x}_i) = \varphi(\mathbf{x}^T) \varphi(\mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2}\right)$ 。

式(5)为改进的 LSSVR 算法。该方法可以防止绝对值过大的  $a_i$  值出现,从而避免决策函数对个别

样本的过度敏感,提高了算法的泛化能力。与传统的LSSVR相似,此方法得到的 $a_i$  ( $\mathbf{a}$ 的第 $i$ 个分量)值多位于零附近,且不等于零。根据支持向量的定义,这些 $a_i$ 值所对应样本都应作为支持向量,导致支持向量过多,影响算法的有效性。

## 1.2 支持向量约束条件及解法

针对LSSVR算法中支持向量过多的问题,提出新的准则强化支持向量的筛选,以求得更有代表性的较少的支持向量集。

随机选择一定数量的样本作为支持向量集,在此基础上,可以根据式(7)计算所有样本点的预测误差值,即:

$$\xi_i = y_i - f(\mathbf{x}_i), i = 1, 2, \dots, l \quad (7)$$

在式(2)中,令 $\nabla_{\xi} L = 0$ ,可得到 $\xi = \frac{\mathbf{a}}{c}$ 。较小的误差绝对值对应了绝对值较小的 $a_i$ ,在目标函数式(3)中,绝对值较小的 $a_i$ 对目标函数的贡献较小。为了减少支持向量数量,应优先剔除对目标函数贡献小的支持向量,保留 $a_i$ 绝对值较大的支持向量。贡献较大的支持向量才被选进支持向量集合,而贡献较小的支持向量将被剔除支持向量集合(令其对应的 $a_i$ 等于零)。因此,提出支持向量约束条件如下:当 $|\xi_i| < \delta'$ ,亦即 $|a_i| < \delta$ , ( $\delta = c\delta'$ )时,令 $a_i = 0$ ,从而剔除这些支持向量。此时式(3)的优化问题就变为如下的带约束的优化问题:

$$\begin{cases} \min H(\mathbf{a}) = \frac{1}{2} \mathbf{a}^T \mathbf{\Omega} \mathbf{a} - \tilde{\mathbf{y}}^T \mathbf{a} \\ |a_i| < \delta \text{ 时}, a_i = 0 \end{cases} \quad (8)$$

式中: $\delta$ —某个正数, $\delta$ 大小与支持向量集的样本数量有关。

式(8)为二次最优化问题,可用搜索法求解。初始值取 $a_i = 0$ , ( $i = 1, 2, \dots, l$ ),选取正数 $\delta$ ,对于第 $i$ 个样本点,在式(8)中对 $a_i$ 求导,令其等于零,求解出 $a_i$ 值,然后根据约束条件判断是否将该样本加入支持向量集合中。

选取 $a_i^{(0)} = 0$ ,  $b = \bar{y}$  和一个正数 $\delta$ ;

对样本点 $i$  ( $i = 1, \dots, l$ ),逐一计算求 $a_i$ 的新值:

$$a_i^{(1)} = (\tilde{y}_i - \sum_j \Omega_{ij} a_j^{(0)}) / \Omega_{ii} \quad (9)$$

若 $|a_i^{(1)}| < \delta$ ,令 $a_i^{(0)} = 0$ ;否则,计算 $\Delta a_i =$

$|a_i^{(1)} - a_i^{(0)}|$ ,然后用 $a_i^{(1)}$ 更新 $a_i^{(0)}$ 的值。

若对于所有的样本点,都有 $\Delta a_i < \varepsilon$ , ( $\varepsilon$ 为某个误差限制),则计算结束,否则重新对样本点逐一计算求 $a_j$ 的新值。

在迭代过程中,只有持续满足约束条件的支持向量样本才能保留下来,这样就避免了支持向量样本在问题域空间某个局部聚集的现象,使得到的支持向量集更有代表性。该迭代过程本质是高斯-塞德尔迭代,且系数阵对角占优,所以必收敛。

## 2 锅炉燃烧优化过程建模

### 2.1 锅炉效率及 $\text{NO}_x$ 生成的影响因素

锅炉效率一般使用反平衡法计算:

$$\eta = 100 - (q_2 + q_3 + q_4 + q_5 + q_6) \quad (10)$$

式中: $\eta$ —锅炉效率; $q_2$ —排烟热损失; $q_3$ —可燃气体未完全燃烧热损失; $q_4$ —固体未完全燃烧热损失; $q_5$ —锅炉散热损失; $q_6$ —灰渣物理热损失。 $\text{NO}_x$ 可分为燃料型 $\text{NO}_x$ 、热力型 $\text{NO}_x$ 和快速生成型 $\text{NO}_x$ ,其中燃料型 $\text{NO}_x$ 占主要部分,另外两者生成量较少。

锅炉效率和 $\text{NO}_x$ 排放浓度与如下锅炉燃烧输入参数:煤种特性、负荷、煤量、入炉总空气量、一次风门开度、二次风门开度、燃烬风门开度和灰渣含碳量等有着密切关系。综合考虑这些量之间的相关性,本文选择锅炉负荷率、煤量、总风量、过量空气系数和二次风率作为输入量;选择锅炉效率和 $\text{NO}_x$ 排放浓度作为输出量。

### 2.2 数据预处理及建模过程

以某600 MW机组锅炉数据为例进行分析。对数据进行标准化处理,在最后输出结果时进行反标准化处理。标准化变换公式为:

$$x^* = (x - \bar{x}) / \sigma^* \quad (11)$$

式中: $x^*$ —标准化后变量; $x$ —某样本数据值; $\bar{x}$ —样本数据的平均值; $\sigma^*$ —样本数据的方差。

使用主成分分析(PCA)对输入变量降维,得到降维后互不相关的新变量,其不仅反映原变量的主要信息,同时还能去除一部分数据噪声,有助于模型训练。

假设由标准化后的 $n$ 组运行数据排成一个矩阵

$X^* = [x_1^*, x_2^*, \dots, x_n^*]^T, x_i^* \in R^m, m$ —输入变量个数。其协方差矩阵为  $G = (X^*)^T X^* / m$ , 求解其特征值(按大小排序)  $\lambda_1 \sim \lambda_m$  与对应特征向量  $V_1 \sim V_m$ 。通过主成分累计贡献率选择  $k$  个主成分,并用对应特征向量构成矩阵  $P = [V_1, V_2, \dots, V_k]$ , 则降维后的矩阵表示为  $U = X^* P$ 。

建模流程:首先读取锅炉运行数据,而后对数据进行标准化处理,用 PCA 法对输入变量降维,进行模型训练,最终输出预测结果,流程如图 1 所示。




图 1 锅炉燃烧建模流程示意图

Fig. 1 Flow chart of boiler combustion modeling

验证测试时,用预测数据均方根误差和平均相对误差作为预测效果衡量标准:

$$RMSE = \sqrt{\frac{\sum_{i=1}^l (y_i - f(x_i))^2}{l - 1}} \quad (12)$$

### 3 建模结果及分析

选用 1000 组数据,其中 900 组数据作为训练集,100 组数据作为测试集进行模型精度测试。通过输入变量的协方差矩阵分解得到特征向量,对应特征值从小到大排列为:

$$\lambda = [0.0028 \ 0.0385 \ 0.7214 \ 0.9982 \ 3.2391]$$

$$\sum_3^5 \lambda_i / \sum_1^5 \lambda_i = 99.174\%$$

经计算,后 3 列特征向量主成分累计贡献率达到 99.174%,故选择它们组成矩阵  $P$ , 重构输入变量。

$$P = \begin{bmatrix} 0.2526 & -0.0468 & 0.5349 \\ 0.9144 & -0.0393 & -0.3492 \\ -0.0584 & -0.9975 & -0.0364 \\ 0.0307 & -0.0140 & 0.5532 \\ 0.3095 & -0.0324 & 0.5334 \end{bmatrix}$$

为对比不同算法建模效果,将经过标准化与 PCA 降维处理后的数据,分别使用 CSVR 算法、LSSVR 算法和 BP 神经网络算法进行建模,并对比分析测试集的预测结果。

#### 3.1 LSSVR 算法模型预测结果

LSSVR 算法设置参数  $\sigma = 1, c = 100$ , 对锅炉效率预测结果如图 2 所示。




图 2 LSSVR 算法的锅炉效率预测值  
Fig. 2 Predicted values of boiler efficiency by LSSVR algorithm

对锅炉  $NO_x$  排放浓度预测结果如图 3 所示。




图 3 LSSVR 算法的锅炉  $NO_x$  排放浓度预测值  
Fig. 3 Predicted values of boiler  $NO_x$  emission concentration by LSSVR algorithm

误差指标如表 1 所示。900 组数据全部为支持向量, LSSVR 模型锅炉效率测试集误差较小;但在锅炉  $NO_x$  排放浓度测试集中,最大相对误差超过了 25%。

表 1 LSSVR 算法预测数据误差(带 PCA)

Tab. 1 Predicted data errors of LSSVR algorithm (with PCA)

参数	最大相对误差/%	均方根误差	平均相对误差/%
锅炉效率	0.108 5	0.000 3	0.024 8
$NO_x$ 浓度	25.853 8	4.809 6	1.267 1

为比较 PCA 降维对模型训练效果的影响,将不使用 PCA 处理,仅做标准化变换的数据,使用 LSSVR 算法建模,测试集的数据误差结果如表 2

所示。

表 2 LSSVR 算法预测数据误差 (不带 PCA)

Tab.2 Predicted data errors of LSSVR algorithm (without PCA)

参数	最大相对误差/%	均方根误差	平均相对误差/%
锅炉效率	-0.100 9	0.000 3	0.025 9
NO <sub>x</sub> 质量浓度	27.060 5	5.149 0	1.368 5

对比表 1 和表 2 可知,输入变量经 PCA 降维处理后,维度由五维降低到三维,但预测误差增长不多,表明原数据的大部分信息得到了保留,模型结构得到了简化。

### 3.2 BP 神经网络模型预测结果

为了与 LSSVR 和 CSVR 算法进行比较,BP 神经网络选择相同的数据进行建模分析,其中隐含层数为 5,每个隐含层神经元数为 10。BP 神经网络模型对锅炉效率预测结果如图 4 所示,对锅炉 NO<sub>x</sub> 排放质量浓度预测结果如图 5 所示,误差指标如表 3 所示。由表 3 可知,BP 神经网络模型预测精度与 LSSVR 算法基本相当,最大预测相对误差绝对值超过 6%。




图 4 BP 神经网络下锅炉效率预测值

Fig.4 Predicted values of boiler efficiency by BP neural network




图 5 BP 神经网络下锅炉 NO<sub>x</sub> 排放质量浓度预测值

Fig.5 Predicted values of boiler NO<sub>x</sub> emission concentration by BP neural network

表 3 BP 神经网络模型预测数据误差

Tab.3 Predicted data errors of model by BP neural network

参数	最大相对误差/%	均方根误差	平均相对误差/%
锅炉效率	0.119 2	0.000 4	0.044 1
NO <sub>x</sub> 质量浓度	6.146 9	4.737 1	1.106 7

### 3.3 CSVR 算法模型预测结果

在 CSVR 算法测试中,锅炉效率预测模型选择了 83 组支持向量,预测结果如图 6 示;NO<sub>x</sub> 排放质量浓度预测模型选择了 117 组支持向量,预测结果如图 7 示,误差指标如表 4 所示。CSVR 算法建模预测精度均较高,最大预测误差不超过 3%。




图 6 CSVR 算法下锅炉效率预测值

Fig.6 Predicted values of boiler efficiency by CSVR algorithm




图 7 CSVR 算法下锅炉 NO<sub>x</sub> 排放质量浓度预测值

Fig.7 Predicted values of boiler NO<sub>x</sub> emission mass concentration by CSVR algorithm

表 4 CSVR 模型预测数据误差

Tab.4 Predicted data errors of CSVR algorithm

参数	最大相对误差/%	均方根误差	平均相对误差/%
锅炉效率	0.086 5	0.000 3	0.027 9
NO <sub>x</sub> 质量浓度	2.939 0	3.015 4	0.997 9

### 3.4 不同算法结果对比

从表 1 到表 4 的数据可知:在预测锅炉效率时,

CSVR 算法平均相对误差为 0.027 9%,略高于 LSSVR 算法的 0.024 8%;在预测锅炉  $\text{NO}_x$  排放质量浓度时,CSVR 算法平均相对误差为 0.997 9%,略低于 LSSVR 算法的 1.267 1%。CSVR 使用的支持向量数量最少,分别只有 83 个和 117 个,而 LSSVR 却高达 900 个。从预测的最大误差来比较,CSVR 算法只有 3%,而 LSSVR 却高达 25.8%。BP 算法介于两者之间。

### 3.5 $\delta$ 取值对算法的影响

CSVR 算法中的参数  $\delta$  取值对模型误差的影响分析如表 5 所示。从表 5 可以看出,随着  $\delta$  取值从 0.1 增加与 0.3,支持向量的个数从 207 个减少到 42 个,模型的误差指标有所增加。因此在使用 CSVR 算法时,需要综合考虑模型的精度与支持向量个数这两个因素来选择  $\delta$  值。

表 5  $\delta$  取值对 CSVR 算法性能影响

Tab.5 Influence of  $\delta$  value on the performance of CSVR algorithm

参数	$\delta$		
	0.1	0.2	0.3
效率预测 SV 个数	207	83	42
效率最大相对误差/%	0.046 2	0.086 5	0.117 5
效率误均方根误差	0.000 15	0.000 31	0.000 49
$\text{NO}_x$ 预测 SV 个数	233	117	76
$\text{NO}_x$ 最大相对误差/%	1.699	2.939	15.603
$\text{NO}_x$ 均方根误差	1.780	3.015	8.023

## 4 结 论

在改进 LSSVR 算法的基础上提出了 CSVR 算法。

以某 600 MW 机组锅炉为例进行数据建模分析。使用 PCA 对数据预处理后,输入变量维数五维降到三维,简化了模型结构,同时又保留了输入数据的主要特征。用 CSVR 算法分别建立锅炉效率和  $\text{NO}_x$  排放浓度的预测模型,与 LSSVR 算法所用的 900 个支持向量相比,在相当的平均预测误差水平上,CSVR 算法所选用支持向量分别只有 83 个和 117 个,远少于 LSSVR 算法选用的 900 个。CSVR

的最大预测相对误差只有 3%,而 LSSVR 却高达 25.8%,表明 CSVR 具有较好的泛化能力。

### 参考文献:

- [1] 罗 嘉,吴 乐. 电站锅炉主要热工过程参数软测量技术研究进展[J]. 热力发电,2015,44(11):1-9,13.  
LUO Jia,WU Le. Research status of soft measurement technology of typical thermal parameters for utility boilers[J]. Thermal Power Generation,2015,44(11):1-9,13.
- [2] 曹庆才,高德欣,刘 芳. 基于神经网络与遗传算法的锅炉燃烧优化系统设计[J]. 自动化技术与应用,2016,35(6):10-14.  
CAO Qing-cai,GAO De-xin,LIU Fang. Design of boiler combustion optimization system based on neural network and genetic algorithm[J]. Techniques of Automation and Applications,2016,35(6):10-14.
- [3] 余廷芳,耿 平,霍二光,等. 基于智能算法的燃煤电站锅炉燃烧优化[J]. 动力工程学报,2016,36(8):594-599.  
YU Ting-fang,GENG Ping,HUO Er-guang,et al. Combustion optimization of a coal-fired boiler based on intelligent algorithm[J]. Journal of Chinese Society of Power Engineering,2016,36(8):594-599.
- [4] 谷丽景,李永华,李 路. 电站锅炉燃烧优化混合模型预测[J]. 中国电机工程学报,2015,35(9):2231-2237.  
GU Li-jing,LI Yong-hua,LI lu. Hybrid model prediction of utility boiler combustion optimization[J]. Proceedings of the CSEE,2015,35(9):2231-2237.
- [5] 彭道刚,梅 兰,李生根,等. 基于大数据和神经网络的锅炉燃烧含氧量建模研究[J]. 热能动力工程,2018,33(9):86-92.  
PENG Dao-gang,MEI Lan,LI Sheng-gen,et al. Research of modeling for the oxygen content of boiler combustion based on large data and neural network[J]. Journal of Engineering for Thermal Energy and Power,2018,33(9):86-92.
- [6] 胡怀中,张建博,刘汉青,等. 采用卷积神经网络的电站锅炉燃烧效率建模方法[J]. 西安交通大学学报,2019,53(10):10-15.  
HU Huai-zhong,ZHANG Jian-bo,LIU Han-qing,et al. Power plant boiler combustion efficiency modeling approach based on convolutional neural networks[J]. Journal of Xi'an Jiaotong University,2019,53(10):10-15.
- [7] 李国强,齐晓宾,陈 彬,等. 循环流化床锅炉燃烧系统的神经网络模型研究[J]. 动力工程学报,2018,38(6):440-446.  
LI Guo-qiang,QI Xiao-bin,CHEN Bin,et al. Modeling research of a CFB boiler combustion system based on neural network[J]. Jour-

nal of Chinese Society of Power Engineering, 2018, 38 ( 6 ): 440 - 446.

[8] 杜树新,吴铁军. 用于回归估计的支持向量机方法[J]. 系统仿真学报,2003,15(11):1580 - 1585,1633.  
DU Shu-xin, WU Tie-jun. Support vector machines for regression [J]. Journal of System Simulation, 2003, 15 ( 11 ): 1580 - 1585,1633.

[9] 顾燕萍, 赵文杰, 吴占松. 基于最小二乘支持向量机的电站锅炉燃烧优化[J]. 中国电机工程学报,2010, 30(17):91 - 97.  
GU Yan-ping, ZHAO Wen-jie, WU Zhan-song. Combustion optimization for utility boiler based on least square-support vector machine[J]. Proceedings of the CSEE, 2010, 30(17) :91 - 97.

[10] 刘吉臻,洪 烽,吕 游,等. 循环流化床锅炉床温动态模型 [J]. 中国电机工程学报,2016,36(8):2168 - 2174.  
LIU Ji-zhen, HONG Feng, LYU You, et al. Dynamic modeling on bed temperature of circulating fluidized bed boiler[J]. Proceedings of the CSEE, 2016, 36(8) :2168 - 2174.

[11] 张文广,张 越,孙亚洲,等. 最小二乘支持向量机联合改进果蝇优化算法的 CFB 锅炉燃烧优化[J]. 热力发电,2016,45

(7):44 - 49.  
ZHANG Wen-guang, ZHANG Yue, SUN Ya-zhou, et al. Combustion optimization for CFB boiler based on least square support vector machine and modified fruit fly optimization algorithm[J]. Thermal Power Generation, 2016, 45(7) :44 - 49.

[12] 李应保,王东风. 一种改进型 LSSVM 模型在电站锅炉燃烧与优化中的应用[J]. 动力工程学报,2018,38(4):258 - 264.  
LI Ying-bao, WANG Dong-feng. Application of an improved LSSVM in combustion modeling and optimization of utility boilers [J]. Journal of Chinese Society of Power Engineering, 2018, 38 (4) :258 - 264.

[13] 丁续达,金秀章,张 扬. 基于最小二乘支持向量机的改进型在线 NO<sub>x</sub> 预测模型[J]. 热力发电,2019,48(1):61 - 67.  
DING Xu-da, JIN Xiu-zhang, ZHANG Yang. An improved online NO<sub>x</sub> prediction model based on LSSVM[J]. Thermal Power Generation, 2019, 48(1) :61 - 67.

(姜雪梅 编辑)

(上接第 119 页)

[8] LU T, LAW C K. On the applicability of directed relation graphs to the reduction of reaction mechanisms[J]. Combustion and Flame, 2006, 146(3) :472 - 483.

[9] TAMÁS T. Applications of sensitivity analysis to combustion chemistry[J]. Reliability Engineering and System Safety, 1997, 57(1) : 41 - 48.

[10] LAM S H, GOUSSIS D A. The CSP method for simplifying kinetics[J]. International Journal of Chemical Kinetics, 2010, 26(4) : 461 - 486.

[11] HU E, LI X, MENG X, et al. Laminar flame speeds and ignition delay times of methane - air mixtures at elevated temperatures and pressures[J]. Fuel, 2015, 158(15) :1 - 10.

[12] BARLOW R, FRANK J. Piloted CH<sub>4</sub>/Air flames C, D, E, and F-release 2. 1[R]. Sandia National Laboratories, 2007.

[13] MAGNUSSEN B F. On the structure of turbulence and a generalized eddy dissipation concept for chemical reaction in turbulent flow-19th Aerospace Sciences Meeting (AIAA) [J]. Otolaryngology-Head and Neck Surgery, 1981, 140(3) :433 - 434.

(丛 敏 编辑)