

# 基于模糊补偿的锅炉主控煤-生物质前馈预测模型

张宝凯

(中国大唐集团科学技术研究总院有限公司华东电力试验研究院,安徽合肥 230031)

**摘要:**为解决生物质大比例直燃耦合燃煤机组中煤-生物质动态前馈微分时间与增益难以精量化整定的难点,提出了基于模糊补偿的锅炉主控前馈预测模型(CF-ICM)。首先,结合锅炉主控前馈,设计建模变量,并利用决策树与最小绝对收缩和选择算子LASSO构建的自适应特征选择方法,对混沌分析的煤量时间序列高维特征以及最大信息系数筛选后的时延建模变量进行特征筛选;其次,采用引力搜索算法GSA优化的局部回归网络ELMAN构建锅炉主控前馈预测模型;最后,建立模糊误差补偿控制器,达到误差修正的目的。基于660 MW超超临界燃煤机组生产数据进行仿真实验,结果表明:CF-ICM模型的预测精度在不同运行工况下均小于0.25;平均绝对百分比误差(MAPE)和均方差(MSE)比深度置信网络DBN、ELMAN、深度神经网络DNN模型均降低了15%和59%以上,相关系数( $R^2$ )提高了1.8%以上。

**关键词:**数据驱动;锅炉主控;特征选择;误差修正

中图分类号:TK227 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2025.04.016

[引用本文格式]张宝凯.基于模糊补偿的锅炉主控煤-生物质前馈预测模型[J].热能动力工程,2025,40(4):143-152. ZHANG Baokai. Fuzzy compensation-based feed-forward prediction model for boiler master control of coal fired boiler coupled biomass[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(4):143-152.

## Fuzzy Compensation-based Feed-forward Prediction Model for Boiler Master Control of Coal Fired Boiler Coupled Biomass

ZHANG Baokai

(East China Electric Power Test & Research Institute of China Datang Group Science and Technology Research Institute Co., Ltd., Hefei, China, Post Code: 230031)

**Abstract:** A feed-forward prediction model (CF-ICM) of boiler master control based on fuzzy compensation was proposed to solve the difficulty of accurately tuning the differential time and gain of coal-biomass for dynamic feed-forward in large-scale direct coupled biomass on coal-fired units. Firstly, combined with boiler master control feed-forward, the modeling variables were designed by using an adaptive feature selection method constructed with decision tree and least absolute shrinkage and selection operator (LASSO) regression, which was developed to perform feature screening on the high-dimensional characteristics of the coal quantity time series analyzed for chaos, as well as the time-delay modeling variables filtered by the maximum information coefficient (MIC); then, the local recurrent network optimized by the gravity search algorithm (GSA) was used to establish the feed-forward prediction model for the boiler master control; finally, a fuzzy error compensation controller was established to achieve the purpose of correcting prediction errors. The simulation experiment was carried out based on 660 MW ultra-supercritical coal-fired unit operational data. The result illustrates that the prediction accuracy of CF-ICM model is less than 0.25 under different operating conditions. The mean absolute percentage error (MAPE) and mean square error (MSE) of the proposed model have been reduced by more than 15% and 59% respectively.

compared with the deep belief network (DBN), ELMAN and deep neural network (DNN) models, while the correlation coefficient ( $R^2$ ) is improved by more than 1.8%.

**Key words:** data-driven, boiler master control, feature selection, error correction

## 引 言

作为再生能源,生物质促进了我国双碳目标下煤炭能源的转型。受限于生物质直接燃烧热值偏低及间接转化后焦油含量高等问题,生物质大比例直燃耦合燃煤发电是实现低成本设备改造的新技术路线之一<sup>[1]</sup>。在以负荷指令为基础的静态前馈煤量以及动态补偿煤量<sup>[2]</sup>函数输出不变的稳态工况下,掺烧生物质燃料改变时,为了满足主蒸汽压力和主蒸汽温度<sup>[3]</sup>的稳定,需要锅炉前馈及时响应,而在前馈动态设计中,控制初始幅度与回归时间点<sup>[4]</sup>的确定需要量化的微分时间与增益,实际调试中很难整定,因此,设计广义智能锅炉主控动态煤-生物质前馈预测模型可以补偿锅炉的动态响应速度和增益,进而实现精确的煤量控制。

传统的生物质机理模型<sup>[5]</sup>难以实现复杂系统未知机理因子的解耦分析与超前控制。随着生产数据的积累以及数据驱动建模技术的发展,在非线性建模方面取得了显著的效果。李大中等人<sup>[6]</sup>采用最小二乘支持向量机(Least Squares Support Vector Machines, LSSVM)模型对生物质气化过程进行建模,为生物质气化剂当量比等指标优化提供了价值参考。Furkan 等人<sup>[7]</sup>结合自回归外生神经网络与模型预测控制(Model Predictive Control, MPC),构建了生物质气化过程辨识模型,增强了最大能源生产潜力。李大中等人<sup>[8]</sup>为解决生物质气化焦油去除过程中不确定、弱相关因素对模型精度造成影响的问题,将灰色关联度分析方法融入到 LSSVM 建模中,成功应用于焦油含量软测量在线分析。李鹏等人<sup>[9]</sup>设计了带有负荷边界约束的生物质直燃耦合燃煤发电综合效益多目标规划模型,实现了环保政策下的高效经济发电。局部回归网络 ELMAN 具有适应时变特性的能力,延时算子的局部状态反馈能够实现网络的快速寻优。因此,本文将采用引力搜索算法(Gravity Search Algorithm, GSA)优化的 ELMAN 神经网络构建锅炉主控前馈预测模型。

实际生产中,由于物料称重变送器测量值传送

至锅炉主控指令之间存在物理滞后<sup>[10]</sup>以及逻辑组态时域模型等延迟环节<sup>[11]</sup>,导致历史服务器中同一时间记录的数据之间缺乏准确的对应关系,从而无法高精度地建立与研究对象相适应的非线性映射。闫来清等人<sup>[12]</sup>采用 k-临近互信息法(Mutual Information, MI)解决了以概率估计为基础的互信息法求取高维特征计算量大、精度低的问题,通过分析变量间的映射相关性,估算延时算子,重构建模数据。但 MI 无法准确捕捉变量间的非线性,并且在处理连续变量离散化过程中容易丢失信息。金秀章等人<sup>[13]</sup>利用最大信息系数(Maximal Information Coefficient, MIC)计算时序变量间的相关性,找出建模输入与输出变量在时序上的一致性,提高了模型的预测精确度。唐振浩等人<sup>[14]</sup>利用 MIC 算法提取了 15 min 内建模初选变量与当前时刻建模对象间的相关性最大时刻,补偿建模时序上的延时,将模型的预测精度控制在 4% 以内。本文将采用 MIC 算法同步各输入变量与锅炉主控指令间的时序一致性,提高预测精度。

为进一步改善预测结果与真实曲线之间的误差,将模型误差补偿引入到建模预测中。杜文莉等人<sup>[15]</sup>利用软测量 LSSVM 模型预测结果,动态构建时序自回归-滑动平均误差校正模型,改善静态 LSSVM 模型,提高系统动态响应。赵景波等人<sup>[16]</sup>针对预测模型预测失配的问题,结合模糊推理规则对误差进行补偿,增强了预测的鲁棒性,以上方法均能得到很好的效果,因此,设计模糊补偿推理,加入到前馈预测模型误差修正中,进一步提升预测精度。

综上所述,本文提出了基于模糊补偿的煤-生物质锅炉主控前馈预测模型,在负荷指令为基础的前馈静态煤量以及动态煤量工作点输出不变的工况下,掺烧生物质改变时,动态预测锅炉主控给煤指令。

## 1 锅炉主控煤-生物质前馈建模设计

某 660 MW 超超临界燃煤机组锅炉主控前馈控制策略如图 1 所示,其指令由静态部分和动态部分构成。

静态部分是由负荷设定与调频功率叠加后的基

础限速指令来控制给煤量,此部分主控前馈具有确 定的函数关系。

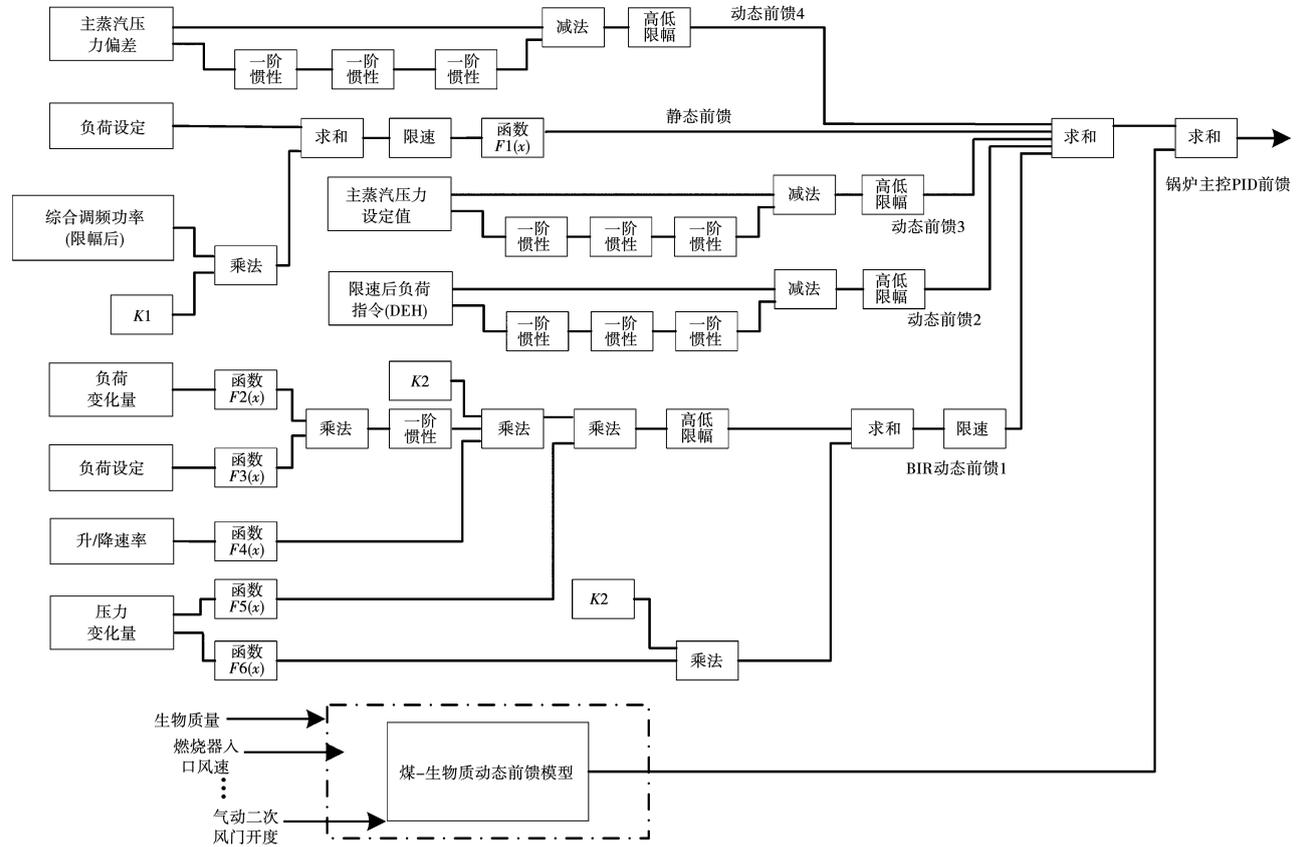


图 1 煤 - 生物质锅炉主控前馈控制组态逻辑图

Fig. 1 Logic diagram of feed-forward control configuration of coal-biomass in boiler master control

动态部分为锅炉输入变化率(Boiler Input Rating, BIR)逻辑实现全面加速,精确补偿由于汽轮机主控调门开度变化引起的负荷瞬态超调量,由压力回头判断系数  $K_2$ , 决定 BIR 控制作用的投/切;主蒸汽压力设定值与主蒸汽压力偏差的三阶惯性环节(动态前馈 3、4)能够保证滑压运行时锅炉侧压力的精准控制,而不会对自动发电控制 AGC 投入品质造成太大影响<sup>[17]</sup>;限速后的负荷指令传送至汽轮机数字电液控制系统 DEH(动态前馈 2)同样作为锅炉蓄热的动态补偿信号,加快锅炉的响应速度。在原有逻辑基础上,设计锅炉主控煤 - 生物质动态前馈预测模型,目的是在静态、动态前馈不变的稳态工况下掺烧生物质改变时实现锅炉主控指令的精准控制,以维持锅炉侧主蒸汽压力和主蒸汽温度的合理波动。

## 2 动态前馈预测模型

### 2.1 模型整体结构

锅炉主控煤 - 生物质动态前馈预测模型建模过

程如图 2 所示,主要分为 4 个部分:

部分 1:根据锅炉主控指令混沌特性分析结果,选出合适的嵌入维数与延迟时间,进行相空间重构,并将重构后的变量作为建模候选输入变量,与此同时,利用 MIC 计算各原始输入变量不同延时尺度序列与主控指令之间的相关性,确定各变量延时序列的最大 MIC 值所对应的序列作为建模候选输入变量;

部分 2:构建自适应特性选择方法,更好地筛选模型候选输入变量;

部分 3:将筛选后的变量输入到 ELMAN 网络中进行训练,并由 GSA 算法寻优网络权值、阈值;

部分 4:构建模糊误差补偿器,进行误差补偿。

### 2.2 数据重构

受人工抓料频次差异、抓取物料重量不一以及破碎、滚筛等设备间上下料皮带传送不均等影响,入炉生物质在额定流量内表现出随机无规律性。采用 Wolf 法<sup>[18]</sup>的李雅普诺夫指数 Lyapunov 估计法对

锅炉主控指令进行混沌特性分析,不同嵌入维数与延时时间参数下的 Lyapunov 指数计算结果如图 3 所示,锅炉主控指令 Lyapunov 指数计算结果均大于

零,说明主控指令具有混沌特性。相空间重构的嵌入维数与延迟时间分别选择 12 和 14 s 时, Lyapunov 指数最小为 0.006 748,表现的混沌特性最小。

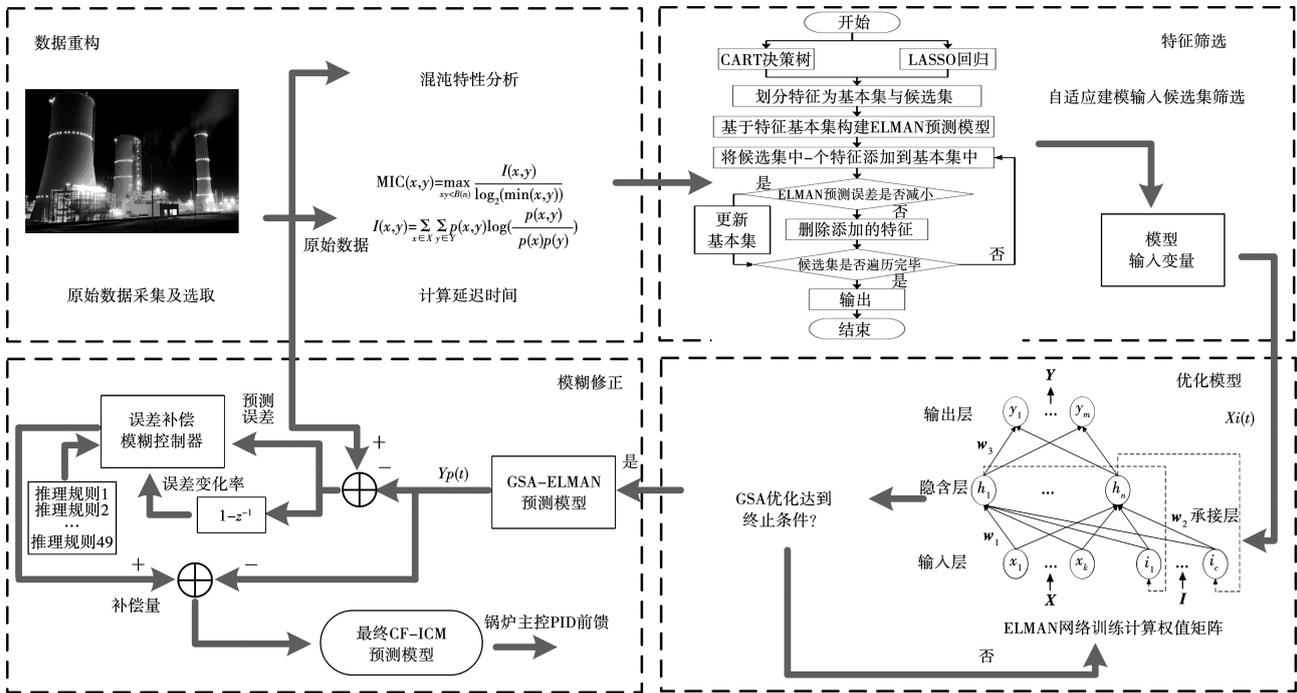


图 2 锅炉主控煤 - 生物质动态前馈预测模型流程图

Fig. 2 Flowchart of dynamic feed-forward prediction model of coal-biomass in boiler master control

炉至锅炉主控 PID 指令变化的延迟时间约为 300 s。建模变量如表 1 所示。

表 1 建模变量

Tab. 1 Modeling variables

变 量	单 位
制备系统输送量 $x_1$	t/h
燃烧器入口风速 $x_2$	m/s
气力输送系统出力风量 $x_3$	t/h
气动热二次风门开度 $x_4$	%
前 $j(j=14,28,42,\dots,168)$ 时刻煤量指令 $x_{(t-j)}$	t/h

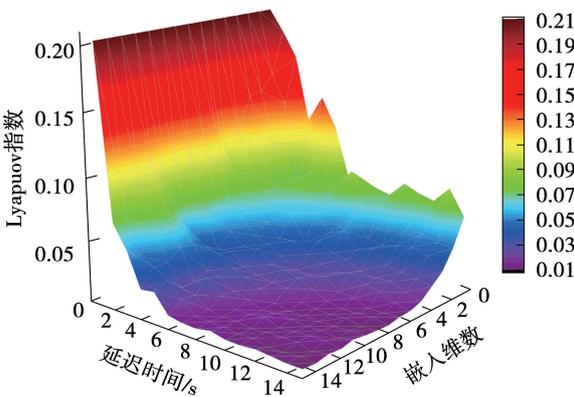


图 3 不同参数下的 Lyapunov 指数计算结果

Fig. 3 Computational result of Lyapunov exponent with different parameters

### 2.3 延时时间确定

采用 MIC 方法计算不同变量延时重构序列与主控指令的相关度,根据相关度大小确定各变量的延时时间。根据现场调试经验,生物质称重烧入

计算变量 ( $x_1 \sim x_4$ ) 在 300 s 内每间隔 5 s 的时间序列  $x_{k(t-i)}$  ( $i=5,10,15\cdots 300, k=1,2,3,4$ ) 与主控煤量指令的相关度,选择最大相关性的间隔序列作为变量的延时时间。延时分析前后  $x_1 \sim x_4$  与主控指令相关性对比如图 4 所示。由图可知,变量的延时时间不同,经过 MIC 计算后,变量 ( $x_1 \sim x_4$ ) 与主控指令的相关性有显著提高。

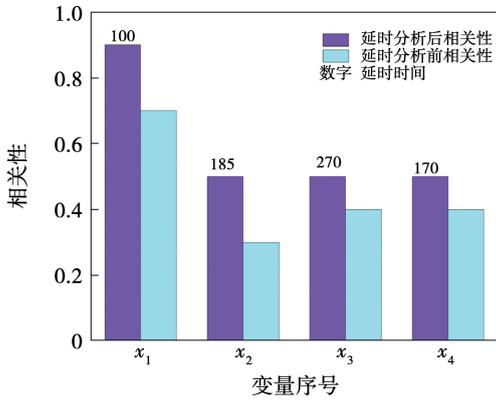


图 4 延时分析前后  $x_1 \sim x_4$  与主控指令相关性对比

Fig.4 Comparison of the correlations between  $x_1 - x_4$  and master control instructions before and after delay time analysis

### 2.4 自适应特征选择

与单一、分步特征选择<sup>[19]</sup>方法不同,本文组合决策树 CART 与 LASSO 回归算法对特征进行自适应选择。

步骤 1:利用决策树与 LASSO 回归算法分别对主控指令高维重构特征及延时建模输入变量进行重要性及标准化系数计算。表 2 为变量( $x_1 \sim x_4$ )延时分析后新变量与煤量指令在嵌入维数与延迟时间分别为 12 和 14 s 时,相空间重构变量的 LASSO 回归模型系数表, CART 重要性排序结果如图 5 所示。

步骤 2:比较 LASSO 回归模型标准化系数不为 0 的特征与 CART 重要性排序结果中前 6 个特征,将共有变量标记为基本集,其余特征标记为待选集;步骤 3:从待选集中抽取一个变量加入基本集中,并构建 ELMAN 模型进行预测,将结果保存;

步骤 4:判断新加入基本集后的 ELMAN 模型预测误差是否减小,是,至步骤 5;否,至步骤 6;

步骤 5:保留待选集中抽取的变量至基本集中,并转至步骤 7;

步骤 6:删除抽取的变量,并转至步骤 7;

步骤 7:判断待选集是否遍历完毕,是,输出;否,至步骤 3。

经自适应特征选择,选择制备系统输送量  $x_{1(t-100)}$ 、燃烧器入口风速  $x_{2(t-185)}$ 、前  $j(j = 14, 28, 56)$ 时刻主控煤量指令  $x_{(t-j)}$ 为建模自变量, $t$ 时刻主

控煤量指令  $y_s$  为建模因变量。

表 2 LASSO 回归模型系数表

Tab.2 LASSO regression model coefficient table

编号	变量	标准化系数	编号	变量	标准化系数
1	$x_{1(t-100)}$	1.088	9	$x_{(t-70)}$	0
2	$x_{2(t-185)}$	-0.047	10	$x_{(t-84)}$	0
3	$x_{3(t-270)}$	0	11	$x_{(t-98)}$	0
4	$x_{4(t-170)}$	0.098	12	$x_{(t-112)}$	0.012
5	$x_{(t-14)}$	0.442	13	$x_{(t-126)}$	-0.003
6	$x_{(t-28)}$	-0.117	14	$x_{(t-140)}$	-0.04
7	$x_{(t-42)}$	0	15	$x_{(t-154)}$	-0.013
8	$x_{(t-56)}$	0.032	16	$x_{(t-168)}$	-0.028

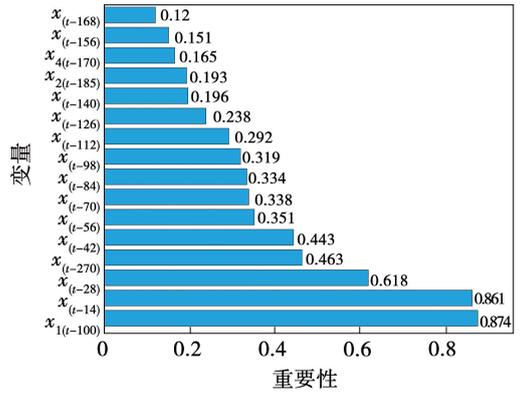


图 5 基于 CART 特征选择的重要性排序  
Fig.5 Importance ranking based on CART feature selection

### 2.5 GSA-ELMAN 模型

ELMAN 递归神经网络<sup>[20]</sup>是将承接层加入到神经网络一般结构中。网络结构如图 6 所示,迭代计算如式(1)~式(3)所示。

$$Y(k) = g(w_3 H(k) + B_1) \quad (1)$$

$$H(k) = f(w_1 X(k-1) + w_2 I(k) + B_2) \quad (2)$$

$$I(k) = \alpha \cdot I(k-1) + H(k-1) \quad (3)$$

式中: $B_1, B_2$ —各层神经元偏置矩阵; $f(\cdot), g(\cdot)$ —激活函数; $w_1, w_2, w_3$ —各层间连接的权重矩阵; $k$ —时间延时因子; $\alpha$ —反馈自增因子,取值在 $[0, 1]$ 之间; $Y = [y_1, y_2, \dots, y_m]$ —建模因变量矩阵; $X = [x_1, x_2, \dots, x_k]$ —建模自变量矩阵; $H = [h_1, h_2, \dots, h_n]$ —隐含层神经元矩阵; $I = [i_1, i_2, \dots, i_c]$ —承接层神经元矩阵。

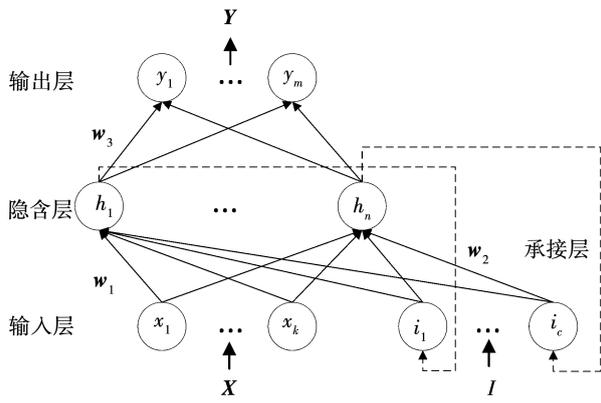


图 6 ELMAN 递归神经网络结构

Fig. 6 ELMAN recurrence neural network structure

采用 GSA 算法寻优 ELMAN 网络权值和阈值步骤:

步骤 1: 将网络权值和阈值作为寻优参数, 设定种群为 50, 初始化粒子位置、速度, 并设置上下限, 引力常量  $G(t)$  为 100;

步骤 2: 将 ELMAN 网络预测结果的均方差设为适应度函数, 并计算种群中个体适应度  $fit_j(t)$ ,  $j=1, 2, i, \dots, 50$ ;

步骤 3: 计算粒子的最佳适应度  $best(t)$  和最差适应度  $worst(t)$ 、粒子的惯性质量。粒子惯性质量  $M_i(t)$  更新式为:

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^{50} m_j(t)} \quad (4)$$

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \quad (5)$$

步骤 4: 根据式(6) ~ 式(8) 计算个体间引力和加速度;

$$F_{ij}^d(t) = G(t) \frac{M_i(t) \times M_j(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t)) \quad (6)$$

$$F_i^d(t) = \sum_{j=1, j \neq i}^{50} \text{rand}_j F_{ij}^d(t) \quad (7)$$

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (8)$$

式中:  $F_{ij}^d(t)$ — $t$ 时刻  $d$  维上, 粒子  $j$  对  $i$  的引力;  $R_{ij}(t)$ — $j$  与  $i$  粒子的欧式距离;  $\varepsilon$ —小常数;  $\text{rand}$ — $[0, 1]$  范围内的随机数;  $G(t)$ —引力常数;  $M_i(t)$ ,  $M_j(t)$ —第  $i$ 、 $j$  个粒子的惯性质量;  $x_j^d(t)$ ,  $x_i^d(t)$ —粒子  $i, j$  在  $t$  时刻  $d$  维上的位置;  $a_i^d(t)$ —粒子  $i$  的加速度。

步骤 5: 更新粒子的位置  $x_i^d$  与速度  $v_i^d$ , 更新式如 (9)、式(10) 所示;

$$v_i^d(t+1) = \text{rand}_i \times v_i^d(t) + a_i^d(t) \quad (9)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (10)$$

步骤 6: 判断是否达到终止条件, 是, 至步骤 7; 否, 至步骤 2。根据实验法, 迭代终止次数设置为 200;

步骤 7: 输出最优权值、阈值赋值给 ELMAN 网络进行预测。

### 2.6 模糊补偿

利用 MATLAB 自带模糊工具箱设计模糊误差补偿控制器, 输入为模型预测值与实际值的偏差  $e(t)$ 、偏差的变化率  $ec(t)$ 。

$$\begin{cases} e(t) = w_r(t) - y_s(t) \\ ec(t) = e(t) - e(t-1) \end{cases} \quad (11)$$

式中:  $w_r$ —参考曲线;  $y_s$ —模型预测值。

采用不规则分布的三角形形状的补偿输出  $\Delta u$ 、 $e(t)$ 、 $ec(t)$  的隶属度函数, 基本论域均设置为  $[-6, 6]$ , 模糊量化因子  $k_e, k_{ec}, k_u$  均为 1, 共设计 7 个模糊子集, 49 条推理规则。模糊子集为 PB(正大)、PM(正中)、PS(正小)、ZO(0)、NS(负小)、NM(负中)、NB(负大)。模糊规则如表 3 所示。

表 3 模糊规则

Tab. 3 Fuzzy rule

偏差的变化率 $ec(t)$	偏差 $e(t)$						
	PB	PM	PS	ZO	NS	NM	NB
PB	NB	NB	NB	NS	NS	NS	ZO
PM	NB	NM	NM	ZO	ZO	ZO	PS
PS	NM	NM	NS	ZO	PS	ZO	PS
ZO	NM	NM	NS	ZO	PS	PS	PM
NS	NM	NM	ZO	ZO	PS	PM	PM
NM	NS	NM	ZO	PS	PM	PB	PB
NB	ZO	NS	PS	PM	PM	PB	PB

### 3 仿真实验

本研究数据采自国内某 660 MW 超超临界 2 号机组分辨率为 1 s 的 DCS 数据, 共 2 000 组, 同时划分为 2 组数据集 D1、D2, 取每组的前 70% 数据为训练集, 其余的 30% 为测试集。

#### 3.1 评价指标

平均绝对百分比误差 (MAPE)、均方差 (MSE) 和相关系数 ( $R^2$ ) 性能评判准则计算式为:

$$\text{MAPE} = \frac{1}{N_z} \sum_{j=1}^{N_z} \left| \frac{x_j - x'_j}{x_j} \right| \times 100\% \quad (12)$$

$$MSE = \sqrt{\frac{1}{N_z} \sum_{j=1}^{N_z} (x_j - x'_j)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{j=1}^{N_z} (x_j - x'_j)^2}{\sum_{j=1}^{N_z} (x_j - \bar{x}_j)^2} \quad (14)$$

式中:  $N_z$ —样本数量;  $x_j, x'_j, \bar{x}_j$ —主控指令实际值、预测值以及实际均值。

MAPE、MSE、 $R^2$  分别代表模型预测结果的可信度、精度以及拟合程度, MAPE 和 MSE 越小越好,  $R^2$  越接近于 1 越好。

### 3.2 实验结果与分析

为了验证 CF-ICM 模型的预测能力, 对比 3 个模型 (DBN 模型、ELMAN 模型和 DNN 模型) 的预测结果, 图 7 为不同模型预测结果与真实值之间的对比。其中, ICM 模型为未经模糊补偿前的锅炉主控前馈预测模型。

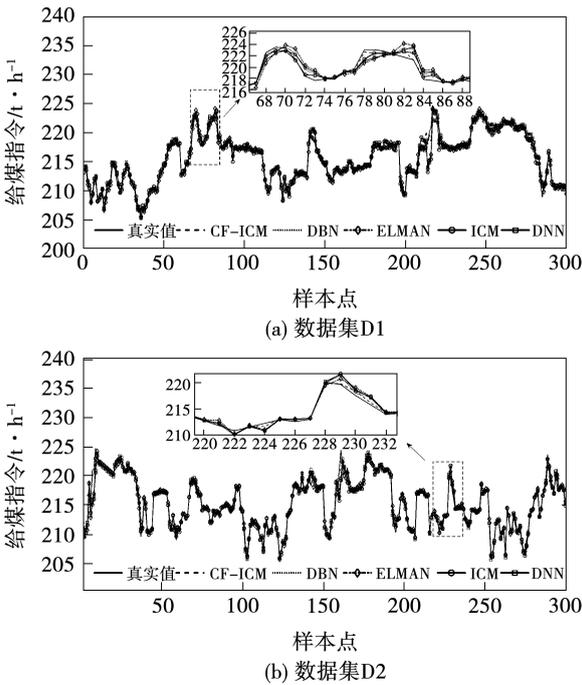


图 7 不同模型的预测结果

Fig. 7 Prediction results of different models

图 7 从折线图方式验证了 CF-ICM 模型比 DBN、ELMAN、DNN 模型以及未经模糊误差修正 ICM 模型预测效果更接近真实曲线变化, 局部截取放大区间更好地反应 CF-ICM 模型拟合真实值的程度, 说明 CF-ICM 模型对煤量指令的预测能力更有效。

表 4 为各模型几种评价指标在数据集 D1、D2 的综合统计信息, 从表 4 可以看出, 在数据集 D1、D2

中 CF-ICM 均取得了比较好的预测结果, 各项评价指标均优于其他 3 种模型。数据集 D1 中, CF-ICM 模型比 ICM 模型的 MAPE 和 MSE 值分别降低了 15.61% 和 59.51%,  $R^2$  提高了 1.89%, 说明模糊误差补偿器明显降低了误差幅度。数据集 D2 中, CF-ICM 模型 MAPE 和 MSE 值相比 DBN 模型分别降低了 20.03% 和 62.18%,  $R^2$  提高了 2.54%。通过以上数据分析, 验证了 CF-ICM 模型的适用性。

表 4 不同算法评价指标结果

Tab. 4 Results of evaluation indicators for different algorithms

数据集	评价指标	CF-ICM	ICM	DBN	ELMAN	DNN
D1	MAPE	0.155 2	0.183 9	0.228 0	0.266 9	0.254 2
	MSE	0.220 1	0.543 6	0.644 9	0.764 8	0.695 1
	$R^2$	0.987 5	0.969 1	0.963 3	0.956 5	0.960 4
D2	MAPE	0.164 9	0.203 0	0.206 2	0.271 4	0.220 4
	MSE	0.246 2	0.665 2	0.651 0	0.880 9	0.726 5
	$R^2$	0.986 5	0.961 2	0.962 0	0.948 6	0.957 6

图 8 为 ICM 模型模糊误差补偿前后相对误差 (真实值与预测值之差) 对比。

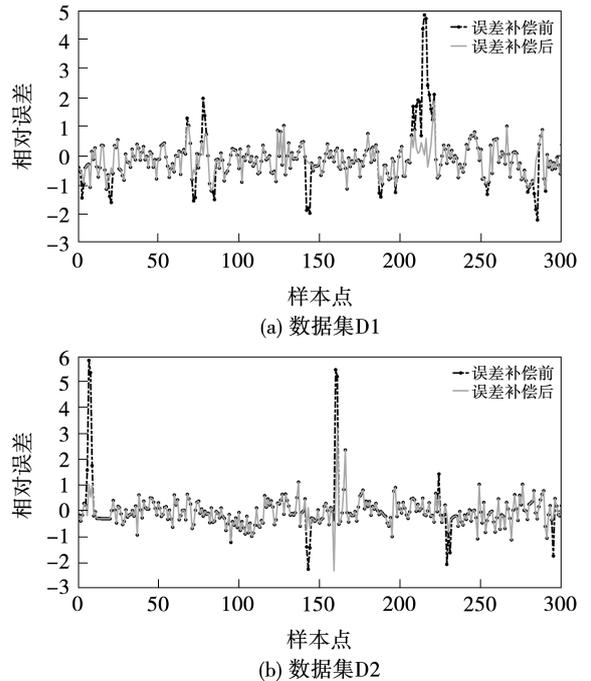


图 8 ICM 模型模糊误差补偿前后相对误差对比  
Fig. 8 Comparison of relative errors before and after fuzzy error compensation of ICM model

从图 8 可以看出, 通过模糊误差补偿, 可以将误差修正至  $[-2, 2]$  范围附近。

### 3.3 延时处理效果分析

确定建模变量的延时时间,找到合适的变量时序对改善模型预测精度至关重要。表 5 为在数据集

D1、D2 中,考虑输入变量有延时时间与无延时时间分析下二种处理方法的评价指标。

表 5 不同模型有/无延时时间实验结果对比

Tab.5 Comparison of experimental results of different models with or without delay time

数据集	评价指标	ICM		DBN		ELMAN		DNN	
		有	无	有	无	有	无	有	无
D1	MAPE	0.183	0.283	0.228	0.320	0.266	0.349	0.254	0.283
	MSE	0.543	0.880	0.644	1.013	0.764	1.085	0.695	0.893
	$R^2$	0.969	0.949	0.963	0.942	0.956	0.938	0.960	0.949
D2	MAPE	0.203	0.346	0.206	0.342	0.271	0.383	0.220	0.356
	MSE	0.665	1.195	0.651	1.132	0.880	1.296	0.726	1.212
	$R^2$	0.961	0.930	0.962	0.933	0.948	0.924	0.957	0.929

以 D1 为例,在考虑有延时情况下,ICM、DBN、ELMAN 和 DNN 模型的预测结果较未考虑延时分析处理的 MAPE 值分别降低了 35.33%,28.75%,23.78% 和 10.25%;MSE 值分别降低了 38.30%,36.43%,29.59% 和 22.17%; $R^2$  提高了 2.11%,2.18%,1.92% 和 1.16%。同样在 D2 中,考虑有延时处理结果的评价指标均优于未经过延时处理的结果。

### 3.4 自适应特征选择效果分析

本节主要讨论自适应特征选择前后 4 种模型预测精度上的差异,模型其他参数设定、延时时间处理均一致。图 9 为在数据集 D2 中不同预测算法有/无特征选择预测结果对比散点图。

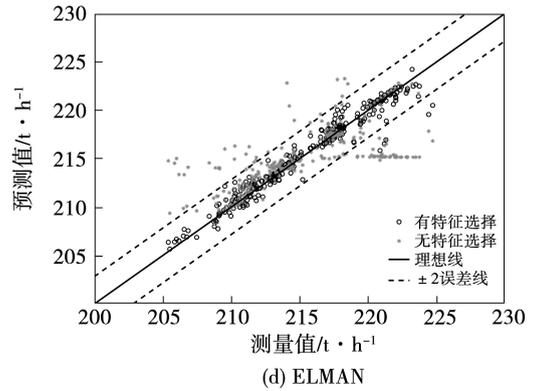
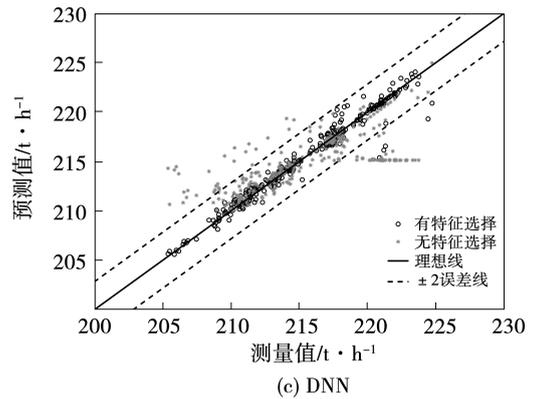
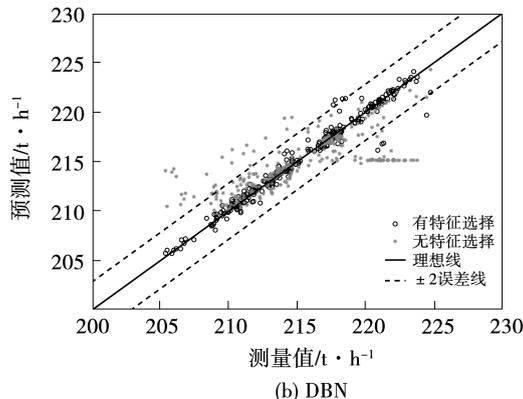
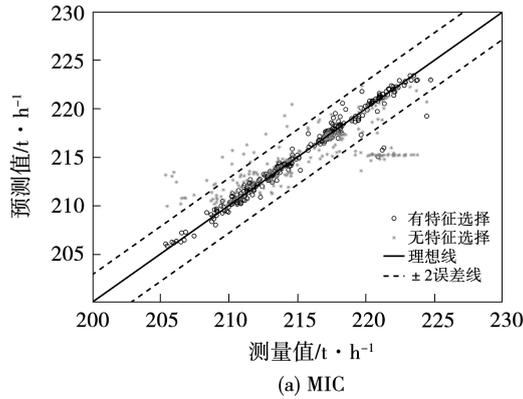


图 9 不同预测算法有/无特征选择预测结果对比散点图

Fig.9 Scatter plots of comparison of prediction results of different prediction algorithms with/without feature selection

从图 9 可以看出,经过自适应特征选择变量后,各模型预测的结果与全部特征作为输入的结果相比,前者更接近真实值分布,误差点基本分布在  $\pm 2$  误差线内。这是由于将所有建模输入变量均进行模型训练,存在冗余以及不相关变量,发生欠拟合,造成模型无法准确预测。

### 3.5 误差补偿效果分析

为了验证模糊误差补偿器的有效性,以 D1 为例,分别采用 ICM、DBN、DNN 和 ELMAN 模型对比误差修正策略前后模型预测精度的差异,表 6 从数据统计角度验证模型经模糊误差补偿后预测精度有所提高。

表 6 预测结果误差补偿对比(是/否补偿)

Tab.6 Comparison of error compensation of prediction results (with/without compensation)

模型	方法	MAPE	MSE	$R^2$
ICM	是	0.155 2	0.220 1	0.987 5
	否	0.183 9	0.543 6	0.969 1
DBN	是	0.183 9	0.296 6	0.983 1
	否	0.228 0	0.644 9	0.963 3
ELMAN	是	0.192 7	0.281 6	0.984 0
	否	0.266 9	0.764 8	0.956 5
DNN	是	0.186 1	0.256 6	0.985 4
	否	0.254 2	0.695 1	0.960 4

由表 6 可知,ICM 模型在误差修正后,MAPE 和 MSE 值分别降低了 15.61% 和 59.51%, $R^2$  提高了 1.90%。DBN 模型 MAPE 值降低了 19.34%, $R^2$  提高了 2.06%,MSE 降低了 54.01%。其他两种模型精度均有明显提高,表明了该方法的有效性。

## 4 结论

(1) 利用最大信息系数确定了与  $t$  时刻锅炉主控指令相一致的各输入延时变量;通过混沌分析确定了与  $t$  时刻锅炉主控指令混沌特性最小的相空间重构嵌入维数和延时时间,补偿了生物质输料过程不均匀性对主控指令的影响。

(2) 设计的自适应特征选择方法消除了冗余、不相关变量对模型预测精度的影响。

(3) 基于 GSA 算法优化的 ELMAN 神经网络构建的动态前馈模型,MAPE 均控制在 0.15 附近,设计的模糊误差补偿器,实现了误差校正统计结果分析,相较于 ICM 模型,CF-ICM 模型的 MAPE 和 MSE 值分别降低 15.16% 和 59.51%, $R^2$  均提高了 1.86%。

(4) CF-ICM 模型的预测性能,MAPE 和 MSE

比深度置信网络 DBN、ELMAN、深度神经网络 DNN 模型均降低了 15% 和 59% 以上, $R^2$  提高了 1.8% 以上,预测精度均小于 0.25。该方法实现了在以负荷指令为基础的静态前馈以及动态补偿煤量函数输出不变的稳态工况下,生物质改变时,精准预测锅炉主控指令。

## 参考文献:

- [1] 兰凤春,李晓宇,龙 辉. 欧洲大型燃煤锅炉耦合生物质发电技术综述[J]. 华电技术,2020,42(10):88-94.  
LAN Fengchun, LI Xiaoyu, LONG Hui. Review of biomass power generation technology coupled with large coal-fired boilers in Europe[J]. Huadian Technology, 2020, 42(10): 88-94.
- [2] 庄义飞,张 剑,陈 涛,等. 超临界火电机组协调控制现状分析及优化[J]. 电站系统工程,2019,35(3):57-60.  
ZHUANG Yifei, ZHANG Jian, CHEN Tao, et al. Status analysis and optimization of coordinated control for supercritical thermal power unit[J]. Power System Engineering, 2019, 35(3): 57-60.
- [3] 刘光鹏,曾 洁,冉桑铭,等. 煤粉锅炉大比例直燃耦合生物质的影响研究及工程应用[J]. 洁净煤技术,2024,30(S2):237-242.  
LIU Guangpeng, ZENG Jie, RAN Shengming, et al. Research and engineering application on the influence of large-scale direct coupled biomass in pulverized coal boiler[J]. Clean Coal Technology, 2024, 30(S2): 237-242.
- [4] 庄义飞. 660 MW 超临界机组协调控制系统优化[D]. 南京:东南大学,2017.  
ZHUANG Yifei. Optimization of coordinated control system for 660 MW supercritical unit[D]. Nanjing: Southeast University, 2017.
- [5] 李昱喆,李 楠,韩 应,等. 生物质-煤耦合发电系统热力学性能分析[J]. 电站系统工程,2019,35(4):1-3,7.  
LI Yuzhe, LI Nan, HAN Ying, et al. Thermal performance analysis of biomass-coal-fired coupled power system[J]. Power System Engineering, 2019, 35(4): 1-3, 7.
- [6] 李大中,王 臻. 基于最小二乘支持向量机的生物质气化过程模型建立[J]. 系统仿真学报,2009,21(3):629-633.  
LI Dazhong, WANG Zhen. Modeling of biomass gasification process based on least squares SVM[J]. Journal of System Simulation, 2009, 21(3): 629-633.
- [7] FURKAN E, OZGUN Y. Data-driven identification and model predictive control of biomass gasification process for maximum energy production[J]. Energy, 2020, 195(C): 117037.
- [8] 李大中,郭 放. 一种融入 GRA 的生物质气化焦油脱除 LSSVM 建模方法[J]. 太阳能学报,2015,36(7):1737-1742.  
LI Dazhong, GUO Fang. A LSSVM modeling method based on GRA for the removal process of biomass asification tar[J]. Acta Energetica

- Solaris Sinica, 2015, 36(7): 1737 - 1742.
- [9] 李鹏, 魏胜民, 郑永乐, 等. 燃煤耦合生物质机组容量优化配置模型[J]. 可再生能源, 2021, 39(7): 893 - 898.  
LI Peng, WEI Shengmin, ZHENG Yongle, et al. Optimal configuration for biomass-coal coupled generation capacity[J]. Renewable Energy Resources, 2021, 39(7): 893 - 898.
- [10] 唐振浩, 柴向颖, 曹生现, 等. 考虑时延特征的燃煤锅炉  $\text{NO}_x$  排放深度学习建模[J]. 中国电机工程学报, 2020, 40(20): 6633 - 6644.  
TANG Zhenhao, CHAI Xiangying, CAO Shengxian, et al. Deep learning modeling for the  $\text{NO}_x$  emissions of coal-fired boiler considering time-delay characteristics[J]. Proceedings of the CSEE, 2020, 40(20): 6633 - 6644.
- [11] 卓旭升, 周怀春, 杨超, 等. 燃煤汽包炉发电机组的动态建模及其运行数据验证[J]. 中国电机工程学报, 2008, 28(17): 26 - 31.  
ZHUO Xusheng, ZHOU Huaichun, YANG Chao, et al. Dynamic modeling for a coal-fired drum boiler power unit and validation through using actual plant data[J]. Proceedings of the CSEE, 2008, 28(17): 26 - 31.
- [12] 闫来清, 董泽. 基于 k - 近邻互信息和 WKOPLS 的 SCR 脱硝系统动态预测模型[J]. 中国电机工程学报, 2019, 39(10): 2970 - 2980.  
YAN Laiqing, DONG Ze. Dynamic prediction model of SCR denitrification system based on k-nearest neighbor mutual information and WKOPLS[J]. Proceedings of the CSEE, 2019, 39(10): 2970 - 2980.
- [13] 金秀章, 刘岳, 于静, 等. 基于变量选择和 EMD-LSTM 网络的出口  $\text{SO}_2$  浓度预测[J]. 中国电机工程学报, 2021, 41(24): 8475 - 8484.  
JIN Xiuzhang, LIU Yue, YU Jing, et al. Prediction of outlet  $\text{SO}_2$  concentration based on variable selection and EMD-LSTM network[J]. Proceedings of the CSEE, 2021, 41(24): 8475 - 8484.
- [14] 唐振浩, 张佳宁, 沈涛. 一种基于卷积特征的  $\text{NO}_x$  排放浓度深度预测模型[J]. 中国电机工程学报, 2023, 43(21): 8356 - 8366.  
TANG Zhenhao, ZHANG Jianing, SHEN Tao. A deep prediction model of  $\text{NO}_x$  emission concentration based on convolution features[J]. Proceedings of the CSEE, 2023, 43(21): 8356 - 8366.
- [15] 杜文莉, 官振强, 钱锋. 一种基于时序误差补偿的动态软测量建模方法[J]. 化工学报, 2010, 61(2): 439 - 443.  
DU Wenli, GUAN Zhenqiang, QIAN Feng. Dynamic soft sensor modeling based on time series error compensation[J]. CIESC Journal, 2010, 61(2): 439 - 443.
- [16] 赵景波, 李瑞年. 基于模糊补偿的预测函数控制的仿真研究[J]. 系统仿真学报, 2003, 15(9): 1325 - 1327.  
ZHAO Jingbo, LI Ruinian. Simulation research of predictive function control based on fuzzy compensation[J]. Journal of System Simulation, 2003, 15(9): 1325 - 1327.
- [17] 张朝阳, 李卫华, 宋兆星. 600 MW 超临界直流炉机组协调控制系统策略[J]. 华北电力技术, 2007, 317(1): 24 - 28.  
ZHANG Zhaoyang, LI Weihua, SONG Zhaoxing. Control strategy of coordination control system of 600 MW unit with supercritical monotube boiler[J]. North China Electric Power, 2007, 317(1): 24 - 28.
- [18] 吕明阳. 燃煤炉窑烧结系统的混沌分析与特征提取[D]. 长沙: 湖南大学, 2020.  
LYU Mingyang. Chaos analysis and feature extraction in sintering system of coal-fired furnaces and kilns[D]. Changsha: Hunan University, 2020.
- [19] 徐子伟. 基于分步特征选择和组合分类器的电信客户流失预测模型[D]. 合肥: 中国科学技术大学, 2016.  
XU Ziwei. A two stage feature selection method and an ensemble classifier based telecom customer churn prediction model[D]. Hefei: University of Science and Technology of China, 2016.
- [20] 赵文清, 郭丙旭, 李刚, 等. 基于智能水滴算法优化 Elman 神经网络的光伏电站输出功率预测[J]. 太阳能学报, 2017, 38(6): 1553 - 1559.  
ZHAO Wenqing, GUO Bingxu, LI Gang, et al. Output power forecast of PV plant based on ELMAN neural network optimized by intelligent water drop algorithm[J]. Acta Energetica Solaris Sinica, 2017, 38(6): 1553 - 1559.

(王治红 编辑)