

DOI: 10.19666/j.rlfed.202303042

# 基于数据驱动的超临界锅炉受热面壁温预测方法

魏小兵<sup>1</sup>, 崔智鹏<sup>2</sup>, 徐婧<sup>2</sup>, 马素霞<sup>2</sup>

(1.晋能控股电力集团阳泉发电有限公司, 山西 阳泉 045100;  
2.太原理工大学电气与动力工程学院, 山西 太原 030024)

**[摘要]** 锅炉受热面管壁超温严重影响电厂的安全运行, 对锅炉受热面壁温进行预测, 提前做出针对性的运行调整, 避免管壁超温, 对锅炉的安全运行具有重要意义。提出一种基于数据驱动的锅炉受热面壁温预测模型。首先, 采用灰色关联分析选取影响受热面壁温的关键特征变量, 构建基于长短时记忆(LSTM)神经网络的壁温预测模型; 然后, 定义历史相似工况下的关联特征系数, 对由LSTM神经网络得到的预测壁温进行修正, 提高模型预测精度; 最后, 以某在役超临界600 MW直流锅炉为研究对象进行分析, 结果表明, 所提出的锅炉受热面壁温预测模型的相对误差在(-2.5%, 2.5%), 平均相对误差为0.40%, 平均壁温预测误差2.24 °C。可见该预测模型可实现复杂工况下锅炉受热面壁温的准确预测。

**[关键词]** 超临界锅炉; 壁温预测; LSTM神经网络; 数据驱动

**[引用本文格式]** 魏小兵, 崔智鹏, 徐婧, 等. 基于数据驱动的超临界锅炉受热面壁温预测方法[J]. 热力发电, 2023, 52(7): 106-112. WEI Xiaobing, CUI Zhipeng, XU Jing, et al. Data-driven method for predicting the wall temperature of heating surface of supercritical boilers[J]. Thermal Power Generation, 2023, 52(7): 106-112.

## Data-driven method for predicting the wall temperature of heating surface of supercritical boilers

WEI Xiaobing<sup>1</sup>, CUI Zhipeng<sup>2</sup>, XU Jing<sup>2</sup>, MA Suxia<sup>2</sup>

(1. Jinneng Power Group Yangquan Power Co., Ltd., Yangquan 045100, China;  
2. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

**Abstract:** The overheating of boiler heating surface seriously affects the safe operation of the power plant. It is of great significance for the safety of boiler to predict the tube temperature of heating surface and to take appropriate preventative measures. A data driven-based model for tube temperature prediction is proposed in this study. Firstly, the key variables affecting the tube temperature are selected by grey correlation analysis that affect the wall temperature of the heating surface, and a wall temperature prediction model based on long short term memory (LSTM) neural network is constructed. Then, the correlation feature coefficients under similar historical operating conditions are defined, and the predicted wall temperature obtained by the LSTM neural network is corrected to improve the model's prediction accuracy. Finally, an on-duty supercritical boiler with 600 MW capacity is taken as the case study. Results showed that the relative error of the proposed prediction model is within (-2.5%, 2.5%). The average relative error is 0.40%, and the average tube temperature prediction error is 2.24 °C. It indicates that the proposed model is helpful for the tube temperature prediction of the boiler under complex operating conditions.

**Key words:** supercritical boiler; wall temperature prediction; long short-term memory networks; data-driven

锅炉受热面超温以及由此导致的爆管事故是影响燃煤发电机组安全运行的痛点问题之一<sup>[1]</sup>。特

别是“双碳”目标下, 可再生能源发电比例逐年提高, 储能技术尚需革命性突破, 电网调峰问题突出,

收稿日期: 2023-03-22

基金项目: 国家重点研发计划项目(2020YFB0606300)

Supported by: National Key Research and Development Program(2020YFB0606300)

第一作者简介: 魏小兵(1975), 男, 高级工程师, 主要研究方向为电厂热工自动控制, LLDLWXB@126.com。

通信作者简介: 徐婧(1989), 女, 博士, 副教授, 主要研究方向为煤电机组智能监控与运行优化, xujing@tyut.edu.cn。

煤电机组承担调峰任务已是其运行新常态<sup>[2]</sup>。然而,负荷频繁波动,特别是深度调峰运行时,炉内压力降低、燃烧工况恶化、循环停滞和传热恶化等问题,增加了受热面超温和爆管的可能性<sup>[3]</sup>。因此,在复杂工况下,对受热面壁温的监测与准确预测,全面客观地了解其变化趋势,提前做出针对性的运行调整,对锅炉的安全运行具有重要意义。

近年来,许多学者为解决锅炉管壁超温问题进行了大量研究,主要可以分为基于实验的方法、基于数值模拟的方法和基于数据驱动的软测量方法。如王小华等<sup>[4-5]</sup>分别对超超临界 1000 MW II 型锅炉和超超临界 660 MW 塔式燃煤锅炉的低负荷管壁超温问题进行了试验研究,并给出了相应的运行调整策略,保证了机组在低负荷下的安全稳定运行;宁新宇等<sup>[6]</sup>通过优化运行氧量及上火风,解决了高温过热器和高温再热器管壁超温问题;然而,基于实验的方法成本较高,且只能针对几个典型工况进行分析验证。喻聪等<sup>[7]</sup>提出了基于燃烧与水动力耦合模型的锅炉蒸汽管壁温度数值模拟方法,对某超临界 660 MW 锅炉壁温进行计算分析;金东昊等<sup>[8]</sup>提出了一种燃煤锅炉屏式过热器壁温耦合数值计算方法,实现了锅炉受热面超温区域的精准预测;Madejski 等人<sup>[8]</sup>构建了锅炉过热器计算流体力学模型,研究了烟气与过热器间复杂传热特性,并预测了过热器表面不同位置温度;Chen 等人<sup>[9]</sup>结合实验和数值模拟方法,分析了超超临界 660 MW 循环流化床锅炉在多种运行工况下的水冷壁温度。这些方法都会对计算模型做一些简化假设,模型精确性不足且复杂度高,数值模拟方法迭代时间长,在工程应用上受到一定的限制。

自刘吉臻院士<sup>[10]</sup>提出数据驱动下的智能发电系统应用架构之后,数据驱动方法<sup>[11]</sup>在发电领域的应用方兴未艾<sup>[12]</sup>。近年来,许多学者结合人工智能算法如卷积神经网络(CNN)和长短时记忆(LSTM)神经网络探讨了数据驱动方法在锅炉壁温预测方面的应用,并取得了一些成果。如 Yin 等人<sup>[13]</sup>构建了考虑时延特性的特征数据集,并利用特征构造、空间分割和特征融合的方法训练了多特征尺度的 CNN 模型,实现了再热器金属温度的准确预测。Hong 等人<sup>[14]</sup>采用 LSTM 神经网络算法训练床层温度预测模型,以给煤率、一次风量、二次风量、AGC 指令和床层温度的历史值作为输入变量,在变负荷工况下得到了良好的预测效果。杨春来等<sup>[15]</sup>使用

LSTM 神经网络算法预测锅炉主蒸汽温度变化趋势,并考虑锅炉运行参数时延特性,提出利用离散粒子群算法优化 LSTM 神经网络模型的时滞变量输入。但现有研究对壁温的预测大都是单时间步长预测,虽然在短时间内有良好的预测效果,但单步预测方法在应对锅炉灵活运行对壁温的影响趋势分析时效果有限。

针对上述问题,本文提出一种基于数据驱动的锅炉受热面壁温多步预测方法。通过麻雀搜索算法(sparrow search algorithm, SSA)对 LSTM 神经网络模型进行参数寻优,构建 SSA-LSTM 壁温预测模型。通过寻找历史相似工况定义关联特征系数,对预测壁温进行修正,提高预测精度,实现多变工况下锅炉受热面壁温及其变化趋势的在线准确预测。

## 1 锅炉受热面壁温预测模型构建流程

本文以历史运行数据为驱动,结合 LSTM 神经网络算法,构建锅炉受热面壁温在线预测模型。该预测模型框架如图 1 所示。

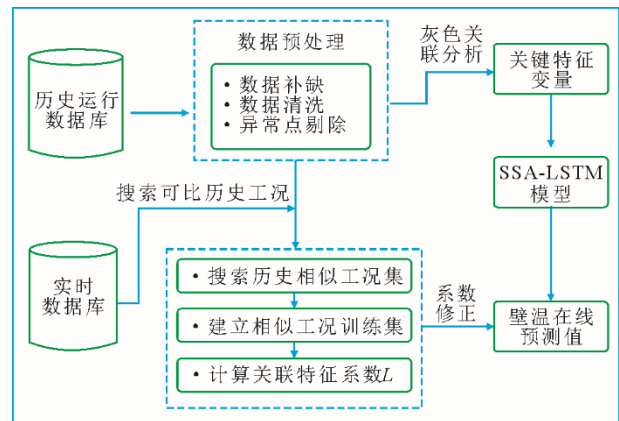


图 1 锅炉受热面壁温在线预测模型框架

Fig.1 Framework of online prediction model for boiler tube temperature

由图 1 可见,本文预测模型流程如下:

1) 采集并获取待分析锅炉历史运行数据,并进行数据补缺、数据清洗与异常点剔除等预处理;

2) 采用灰色关联分析(grey relation analysis, GRA)选取影响受热面壁温的关键特征变量作为输入,借助 SSA 对 LSTM 神经网络模型超参数寻优,构建锅炉受热面壁温预测模型;

3) 搜索历史相似工况,计算关联特征系数,对 LSTM 神经网络预测壁温进行修正,提高预测精度,实现锅炉受热面壁温的在线准确预测。

## 2 锅炉受热面壁温预测模型构建

### 2.1 数据预处理

数据的规模和质量是保证以数据驱动为基础的受热面壁温预测模型准确性的前提。因此,需要对采集得到的原始数据中存在的缺失、重复、错误等不规则数据进行清洗处理。本文采用相邻数据的平均值对少量缺失值进行填充;根据机组设计资料及热力试验资料,确定运行参数正常数值范围,当其超过正常范围时,将其视为异常数据,直接剔除。本文选取案例机组主要参数及其区间见表 1。

表 1 案例锅炉主要参数及其运行区间

Tab.1 Case boiler main parameters and operating interval

项目	区间	项目	区间
锅炉负荷/MW	[235, 672]	屏式过热器出口汽温/°C	[440, 546]
过热器出口蒸汽流量/(kg·s <sup>-1</sup> )	[189, 540]	屏式过热器入口汽温/°C	[342, 465]
再热器出口蒸汽流量/(kg·s <sup>-1</sup> )	[163, 441]	分离器出口汽温/°C	[317, 426]
省煤器进口水流量/(kg·s <sup>-1</sup> )	[189, 540]	再热器进口汽温/°C	[247, 327]
高温过热器出口汽温/°C	[470, 571]	再热器出口汽温/°C	[434, 569]
高温过热器入口汽温/°C	[440, 528]	省煤器出口水温度/°C	[247, 318]

### 2.2 基于灰色关联分析的关键特征变量选取

锅炉受热面壁温受烟气侧传热特性和管内工质吸热冷却特性 2 方面的共同作用。因此,锅炉中风、烟、水、汽等多种介质参数都会影响受热面壁温。为降低预测模型的空间纬度,尽可能提高数据的稠密度,本文采用 GRA 确定影响受热面壁温的关键因素,并作为模型的输入。GRA 通过计算 2 个变量之间相似或相异程度,衡量变量间的关联程度<sup>[16]</sup>。选取锅炉主要运行参数作为条件变量,受热面壁温作为决策变量,计算其灰色关联系数:

$$\xi_k = \frac{\Delta_{\min} + \rho \Delta_{\max}}{\Delta_k + \rho \Delta_{\max}} \quad (1)$$

式中:  $\xi_k$  表示第  $k$  时刻关联系数;  $\Delta_k$  表示 2 个关联数列同一样本点  $k$  时刻的差值;  $\Delta_{\min}$  与  $\Delta_{\max}$  分别表示该差值的最小值与最大值;  $\rho$  表示分辨系数,  $\rho$  越小,分辨力越大,本文取 0.5。

不同影响因素与锅炉受热面壁温之间的灰色关联度为:

$$\gamma_i = \frac{1}{m} \sum_{k=1}^m \xi_k \quad (2)$$

式中:  $\gamma_i$  表示第  $i$  个主要运行参数与受热面壁温的灰色关联度,  $\gamma_i$  越大则表明该参数与受热面壁温之间的关联性越强。

### 2.3 基于 SSA-LSTM 锅炉受热面壁温预测模型

#### 2.3.1 LSTM 神经网络

LSTM 神经网络<sup>[17]</sup>在传统递归神经网络的隐藏层节点上设置乘法单元(包括输入门、输出门和遗忘门)来控制传输状态,其结构如图 2<sup>[18]</sup>所示。

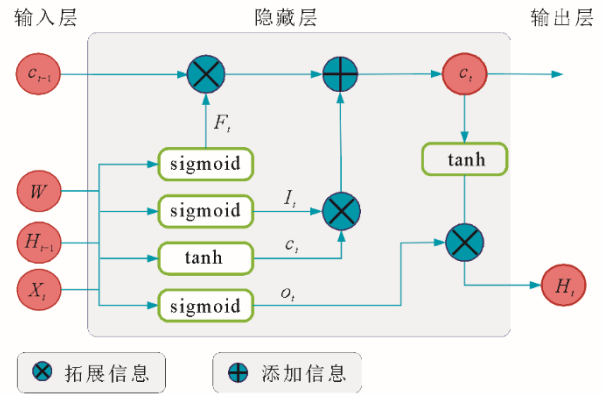


图 2 LSTM 神经网络隐藏层内部结构

Fig.2 LSTM neural network hidden layer internal structure

LSTM 神经元迭代计算如下:

$$F_t = \text{sigmoid}(W_F X_t + W_F H_{t-1} + B_F) \quad (3)$$

$$I_t = \text{sigmoid}(W_I X_t + W_I H_{t-1} + B_I) \quad (4)$$

$$O_t = \text{sigmoid}(W_O X_t + W_O H_{t-1} + B_O) \quad (5)$$

$$H_t = O_t \tanh(c_t) \quad (6)$$

$$B_t = I_t c_t + F_t B_{t-1} \quad (7)$$

$$c_t = F_t c_{t-1} + I_t \tanh(W_c X_t + W_c H_{t-1} + B_c) \quad (8)$$

$$\text{sigmoid} = \frac{1}{1 + e^{-x}} \quad (9)$$

$$f_{\text{loss}} = \frac{\sum_{i=1}^{H(m-H)} (P_i - y_i)^2}{H(m-H)} \quad (10)$$

式中:  $t$  为时刻;  $F_t$  为遗忘门;  $I_t$  为输入门;  $O_t$  为输出门;  $c_t$  为单元状态向量; sigmoid 和双曲正切函数 tanh 为 2 个激活函数;  $W_F$ 、 $W_I$ 、 $W_O$ 、 $W_c$  分别为遗忘门、输入门、输出门和单元状态向量的权重;  $B_F$ 、 $B_I$ 、 $B_O$ 、 $B_c$  分别为遗忘门、输入门、输出门和单元状态向量的偏置项;  $h_{t-1}$  为内存块在  $t-1$  时刻的输出;  $X_t$  为  $t$  时刻的输入;  $f_{\text{loss}}$  为损失函数;  $H$  为分割窗长度;  $m$  为训练集维度;  $P_i$  为模型反演值;  $y_i$  为模型真实值。

LSTM 神经网络模型的训练过程如下:

1) 在 LSTM 神经网络模型的输入层中输入数据  $X_t$ , 然后向前传播, 并输入隐藏层;

2) 隐藏层接收到输入层传入的  $X_t$  以及上一时刻的  $H_{t-1}$  和  $c_{t-1}$ , 计算得到当前时刻的  $H_t$  和  $c_t$ ;

3) 利用  $O_t$  和  $c_t$  计算得到  $H_t$ , 并将隐藏层的  $H_t$  和  $c_t$  传递给下一时刻的神经单元;

4) 采用式(10)计算损失函数, 采用梯度反向传播的方法实现参数权值的更新;

5) 重复以上的步骤, 直到模型收敛或者达到训练的终止条件。

### 2.3.2 SSA 优化 LSTM 神经网络模型超参数

LSTM 神经网络模型精度由其超参数 (隐含层神经元个数、随机失活比率和单次训练样本数) 决定。本文采用 SSA<sup>[19]</sup>对 LSTM 神经网络模型超参数进行寻优, 其流程如图 3 所示。

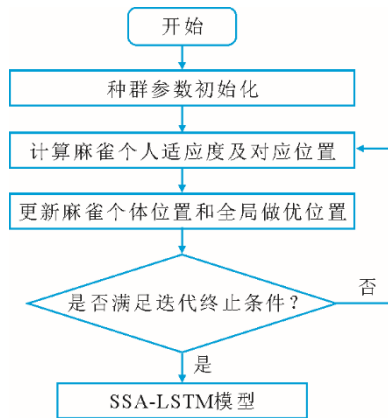


图 3 基于 SSA 的 LSTM 神经网络模型超参数寻优  
Fig.3 LSTM neural network model hyper parameters optimization based on SSA

基于 SSA 的 LSTM 神经网络模型超参数寻优流程包含以下步骤<sup>[20]</sup>:

1) 初始化参数 具体包括种群数量、发现者和警戒者的比例、最大迭代次数  $r_{max}$ , 警戒阈值  $R_2 \in [0, 1]$ , 安全阈值  $ST \in [0.5, 1.0]$ ; 初始化种群个体位置  $X_i = [x_{1,i}, x_{2,i}, \dots, x_{d,i}]$ ,  $i=1, 2, \dots, D$ ;  $x_{d,i}$  表示第  $i$  只麻雀在第  $d$  维的位置。

2) 计算麻雀个体的适应度值及对应位置 从高适应度的麻雀群体中随机选择 20% 作为发现者, 其余麻雀个体作为加入者。

3) 更新麻雀个体位置和全局最优位置 发现者位置更新如式(11)所示, 加入者的位置更新如式(12)所示:

$$X_{i,(r+1)} = \begin{cases} X_{i,(r)} \cdot \exp(-i / (\alpha_2 \cdot r_{max})), & R_2 \leq ST \\ X_{i,(r)} + Q \cdot L, & R_2 > ST \end{cases} \quad (11)$$

$$X_{i,(r+1)} = \begin{cases} Q \cdot \exp((X_{worst,(r)} - X_{i,(r)}) / i^2), & i > n/2 \\ X_{p,(r)} + |X_{i,(r)} - X_{p,(r+1)}| \cdot A^+ \cdot L, & i \leq n/2 \end{cases} \quad (12)$$

式中:  $r$  为当前迭代次数;  $\alpha_2$  为  $[0,1]$  的随机数;  $Q$  为

一个服从正态分布的随机数;  $L$  为一个  $1 \times D$  维的全一矩阵;  $X_{worst,(r)}$  为第  $r$  代种群中适应度值最低的麻雀个体位置;  $X_{p,(r)}$  为第  $r$  代种群中适应度值最高的麻雀个体位置;  $A$  为一个  $1 \times D$  维的矩阵, 其中每一维都随机从  $\{-1,1\}$  中选取, 而  $A^+ = A^T(AA^T)^{-1}$ 。

4) 做终止条件的判断及检验 若达到最大迭代次数则停止循环, 输出 LSTM 神经网络模型最佳超参数; 否则退回至步骤 2) 继续计算。

### 2.3.3 基于关联特征系数的预测壁温修正

为进一步提高受热面壁温多步预测模型准确性, 本文根据历史相似工况的可比性定义关联特征系数  $L$ , 对 SSA-LSTM 模型进行修正, 计算公式为:

$$L = \sum_{i=1}^n \sigma_x x_i \quad (13)$$

式中:  $n$  表示关键特征变量数;  $\sigma_x$  表示数据相关系数, 由 GRA 得到的灰色关联系数归一化所得, 且  $\sigma_1 + \sigma_2 + \dots + \sigma_n = 1$ ;  $x_i$  表示经归一化后的关键特征变量的历史运行数据。

关联特征系数  $L$  对 SSA-LSTM 模型的壁温预测值的修正包含以下步骤:

1) 搜索历史相似工况集 根据当前工况下的关联特征系数  $L_t$ , 从历史运行数据中搜索相似工况集, 搜索准则为  $L_t \in [(1-\alpha) \times L_i, (1+\alpha) \times L_i]$ , 其中,  $\alpha$  为相似系数, 表示相似工况筛选强度, 一般取 0.05。

2) 建立历史相似工况训练集 计算历史相似工况集内关联度特征系数  $L_i$ , 其中  $i=1, 2, \dots, N$ ,  $N$  为历史相似工况集内样本个数; 并将  $\Delta L_i = |L_t - L_i|$  由小到大排序, 选择前  $K$  个样本构成历史相似工况训练集。关联度特征差值越小, 则历史工况与当前工况相似度越高。文中  $K$  取 5。

3) 参数计算 由式(14)一式(16)计算历史相似工况训练集中的历史关联特征系数的平均值  $L_h$ , 历史壁温实测值的平均值  $T_{hc}$  和 SSA-LSTM 模型得到的历史壁温预测值的平均值  $T_{hp}$ 。

$$L_h = \frac{1}{K} \sum_{j=1}^K L_j \quad (14)$$

$$T_{hc} = \frac{1}{K} \sum_{j=1}^K T_{c_j} \quad (15)$$

$$T_{hp} = \frac{1}{K} \sum_{j=1}^K T_{p_j}, \quad j=1, 2, \dots, K \quad (16)$$

式中:  $L_j$  表示历史相似工况训练集内样本的关联度特征系数;  $T_{c_j}$  表示在历史相似工况训练集内壁温的历史实测值;  $T_{p_j}$  表示历史相似工况训练集内由

SSA-LSTM 模型得到的历史壁温预测值。

经关联特征系数修正后的壁温  $T_f$  可表示为:

$$T_f = \frac{L_t}{L_h} (T_{hc} - T_{hp}) + T_p \quad (17)$$

### 3 应用实例

#### 3.1 研究对象

本文以英国三井巴布科克公司制造的 HG-1944/24.7-PM6 型某在役变压运行螺旋管圈直流锅炉为案例进行分析。该锅炉是单炉膛、一次中间再热、旋流燃烧器前后墙对冲燃烧方式、平衡通风、露天布置、固态排渣、全悬吊钢构架的 II 型结构。锅炉为超临界 600 MW 直流锅炉, 锅炉最大连续蒸发量为 672 MW, 过热器出口蒸汽额定温度为 571 °C, 再热器出口额定流量为 1 588.5 t/h, 额定压力为 4.49 MPa, 额定温度为 569 °C。

该厂配置有厂级信息监控系统 (supervisory information system, SIS), 从 SIS 中选取 2021 年 2 月、5 月、8 月和 11 月的锅炉壁温相关历史运行数据, 数据采样间隔为 1 min, 共计 193 540 组数据。经数据预处理后保留 177 120 组数据, 其随负荷分布情况如图 4 所示。




图 4 数据预处理后机组不同负荷出现的频次  
Fig.4 Data distribution after data preprocessing

寻找热负荷偏差较大、频繁超温的位置, 确定不同受热面壁温的冷却措施响应时长。通过对历史运行数据分析发现, 屏式过热器 (屏过) 15 号测点位置处在不同负荷阶段, 其壁温都偏高 (图 5)。锅炉的屏过在炉深方向单排布置, 管屏沿炉宽方向布置 30 片屏, 每片屏由 24 根管绕成。屏过壁温测点设在从锅炉左侧数起第 2—第 25 片管屏上, 共 24 个测点。其中, 15 号测点位于屏过第 16 屏的 20 号管束外侧。本文选取屏过 15 号测点位置为研究对象进行分析。对其他超温位置的分析方法同理, 在此不做赘述。

屏过的主要降温措施为调节喷水减温水流量,

通过分析该位置壁温随减温水的响应特性 (图 6) 可以看出, 在 10 min 时一级喷水减温水流量增加, 15 号测点位置壁温在 14:40 开始响应降低, 可见, 该处壁温响应时长为 280 s。因此, 应至少预留屏过 5 min 后的壁温变化, 以保证预留足够的时间采取降温措施。




图 5 屏过壁温统计结果  
Fig.5 Statistical results of platen superheater wall temperature




图 6 屏过 15 号测点壁温响应  
Fig.6 Temperature response of tube 15 in platen superheater

#### 3.2 实例分析

结合历史数据分别对 38 个影响壁温的主要因素进行灰色关联分析并排序, 结果见表 2。设定关联度阈值为 0.85, 由此选择排名前 11 位的影响锅炉壁温的关键特征变量进入作为 SSA-LSTM 壁温预测模型的输入。同时, 考虑到磨煤机组合方式、同层燃烧器热负荷、配风方式等因素对壁温的影响, 增加锅炉负荷作为模型输入变量。随机选取 80% 数据集合作为模型训练集, 剩余 20% 数据作为测试集。经过 SSA 优化的 LSTM 神经网络模型超参数见表 3。

本文采用均方根误差  $\delta_{RMSE}$  评价 SSA-LSTM 模型训练结果, 即为:

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2} \quad (18)$$

式中:  $x_i$ 、 $x'_i$  分别为壁温实测结果与模型预测结果;  $n$  为数据样本数。 $\delta_{RMSE}$  越小, 模型预测精度越高。

为减小 SSA-LSTM 模型的预测误差, 本文提出

基于关联特征系数的预测壁温修正。图 7 为壁温预测结果修正前后误差对比。由图 7 可见，经过关联系数修正后，在预测的 5 min 内，修正模型的  $\delta_{RMSE}$  均降低，预测精度都有所提升。

表 2 灰色关联分析结果及排序  
Tab.2 Grey correlation coefficient of variables and ranking

参数	$\gamma_i$	排名	参数	$\gamma_i$	排名
减温水后汽温-1A	0.91	1	再热减温器后汽温	0.79	20
末级过热器出口汽温-A	0.91	2	低温过热器出口汽温	0.78	21
低温再热器壁温	0.89	3	尾部烟气挡板调节阀位	0.77	22
减温水后汽温-2A	0.89	4	汽水分离器出口汽温	0.77	23
减温水流量-2A	0.88	5	锅炉给水流量	0.75	24
末级过热器出口汽温-B	0.87	6	总风量	0.75	25
减温水后汽温-1B	0.86	7	总给煤量	0.75	26
减温水后汽温-2B	0.86	8	凝结水流量	0.75	27
减温水流量-2B	0.85	9	锅炉负荷	0.74	28
省煤器出口给水温度	0.85	10	低旁入口压力	0.74	29
风水比	0.85	11	除氧器压力	0.74	30
炉膛负压	0.84	12	实际二次风量	0.74	31
减温水流量-1A	0.84	13	二次风温	0.74	32
空气预热器烟气入口含氧量	0.84	14	低温再热器入口压力	0.74	33
风煤比	0.84	15	末级过热器出口压力	0.74	34
水煤比	0.84	16	主蒸汽压力	0.73	35
减温水流量-1B	0.83	17	锅炉给水温度	0.73	36
烟气出口含氧量	0.83	18	锅炉给水压力	0.73	37
热一次风压	0.81	19	省煤器入口给水温度	0.73	38

表 3 SSA-LSTM 模型超参数优化结果  
Tab.3 Optimal hyper parameters of SSA-LSTM model

参数	最佳模型参数	参数寻优范围
第 1 层神经元个数	150	50~300
第 2 层神经元个数	8	5~15
单批量样本数	32	8~64
丢弃率	0.5	0.05~0.5




图 7 壁温预测结果修正前后误差对比  
Fig.7 Error comparison of wall temperature prediction results before and after correction

图 8 为 SSA-LSTM 模型与关联特征系数修正模型在预测 5 min 时壁温的相对误差对比。由图 8 可以看出，SSA-LSTM 模型 5 min 时相对误差在 (-3%, 3%)，经计算平均相对误差为 0.68%，平均

误差 3.81  $^\circ\text{C}$ ， $\delta_{RMSE}=14.75$   $^\circ\text{C}$ ；经关联特征系数修正后的模型在 5 min 时的相对误差在 (-2.5%, 2.5%)，平均相对误差 0.40%，平均误差 2.24  $^\circ\text{C}$ ， $\delta_{RMSE}=11.31$   $^\circ\text{C}$ ，均方根误差降低 23.3%。可见本文提出的基于关联特征系数修正的壁温预测模型能够有效提高壁温多步预测精度。




图 8 屏过壁温预测误差  
Fig.8 Wall temperature prediction error of platen superheater

图 9 展示了在部分运行时段，经关联特征系数修正后的 5 min 壁温预测结果。由图 9 可以看出，经关联特征系数修正后的模型可准确预测锅炉受热面壁温的变化趋势，有助于运行人员尽早采取合理的降温措施，保证锅炉安全运行。




图 9 屏过壁温预测结果  
Fig.9 Wall temperature prediction results of platen superheater

## 4 结 论

本文基于锅炉历史运行数据，结合 SSA-LSTM 组合算法，构建了锅炉受热面壁温多步预测模型，并结合关联特征系数对预测模型进行修正，实现了锅炉壁温在线准确预测。以某在役超临界 600 MW 锅炉为研究对象进行分析，得到以下结论：

1) 本文提出受热面壁温预测模型在进行多步壁温预测时，最大相对误差在 (-2.5%, 2.5%)，平均相对误差 0.40%，平均壁温预测误差 2.24  $^\circ\text{C}$ ，模型精度可满足在线监测和分析的需求。

2) 通过搜索相似工况，定义关联特征系数对 SSA-LSTM 预测模型进行修正，可使模型均方根误

差降低 23%，有效提高受热面壁温多步预测精度。本文提出锅炉受热面壁温多步预测模型可以实现多工况下壁温变化趋势的准确研判。

3) 本文中提出的预测模型误差随着预测时长的增加而增大，因此，在实际应用时应根据锅炉自身响应特征选取合适的预测时长。

### 【参考文献】

- [1] 金东昊, 刘欣, 张效源, 等. 燃煤锅炉屏式过热器壁温耦合计算方法[J]. 中国电机工程学报, 2022, 42(24): 8951-8961.  
JIN Donghao, LIU Xin, ZHANG Xiaoyuan, et al. A coupled model for predicting the tube temperature of platen superheater of coal-fired boiler[J]. Proceedings of the CSEE, 2022, 42(24): 8951-8961.
- [2] 弓林娟, 侯国莲, 胡博, 等. 面向低碳灵活运行的超临界机组模糊预测控制策略[J]. 中国电机工程学报, 2023, 43(3): 1048-1059.  
GONG Linjuan, HOU Guolian, HU Bo, et al. Fuzzy predictive control strategy for low-carbon flexible operation of supercritical unit[J]. Proceedings of the CSEE, 2023, 43(3): 1048-1059.
- [3] LI X, YU X. Robust regulation for superheated steam temperature control based on data-driven feedback compensation[J]. Applied Energy, 2022, 325: 119918.
- [4] 王小华, 张战锋, 黄伟珍, 等. 1 000 MW 机组锅炉低负荷下管壁超温诊断及运行优化调整[J]. 热能动力工程, 2019, 34(8): 80-86.  
WANG Xiaohua, ZHANG Zhanfeng, HUANG Weizhen, et al. Overtemperature diagnosis and optimal adjustment of tube wall temperature of a 1 000 MW unit boiler under low load condition[J]. Journal of Engineering for Thermal Energy and Power, 2019, 34(8): 80-86.
- [5] 王小华, 刘瑞鹏, 丁奕文, 等. 660 MW 超超临界机组不同炉型高温再热器管壁温度分布规律研究[J]. 热能动力工程, 2021, 36(7): 145-150.  
WANG Xiaohua, LIU Ruipeng, DING Yiwen, et al. Study on 660 MW ultra supercritical unit of different furnace type high temperature reheater tube wall temperature distribution[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(7): 145-150.
- [6] 宁新宇, 刘忠轩, 孙拴柱, 等. 1 000 MW 超超临界塔式锅炉过热器、再热器管壁壁温超温分析与试验研究[J]. 锅炉技术, 2019, 50(4): 29-33.  
NING Xinyu, LIU Zhongxuan, SUN Shuanzhu, et al. Analysis and experimental research on overtemperature of superheat and reheat wall for a 1 000 MW tower type ultra-supercritical boiler[J]. Boiler Technology, 2019, 50(4): 29-33.
- [7] 喻聪, 司风琪, 李敏, 等. 基于燃烧与水动力耦合模型的锅炉蒸汽管超温特性研究[J]. 热能动力工程, 2021, 36(8): 92-98.  
YU Cong, SI Fengqi, LI Min, et al. Study on Overtemperature of boiler steam tube base on coupling model of combustion and hydrodynamic[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(8): 92-98.
- [8] MADEJSKI P, TALER D, TALER J. Thermal and flow calculations of platen superheater in large scale CFB boiler[J]. Energy, 2022, 258: 124841.
- [9] CHEN Z, HAO Y S, SUN L, et al. Phase compensation based active disturbance rejection control for high order superheated steam temperature system[J]. Control Engineering Practice, 2022, 126: 105200.
- [10] 刘吉臻, 王庆华, 房方, 等. 数据驱动下的智能发电系统应用架构及关键技术[J]. 中国电机工程学报, 2019, 39(12): 3578-3587.  
LIU Jizhen, WANG Qinghua, FANG Fang, et al. Data-driven-based application architecture and technologies of smart power generation[J]. Proceedings of the CSEE, 2019, 39(12): 3578-3587.
- [11] TAO F, QI Q, WANG L, et al. Digital twins and cyber-physical systems toward smart manufacturing and industry 4.0: correlation and comparison[J]. Engineering, 2019, 5(4): 653-661.
- [12] TENG S Y, TOUŠ M, LEONG W D, et al. Recent advances on industrial data-driven energy savings: digital twins and infrastructures[J]. Renewable and Sustainable Energy Reviews, 2021, 135: 110208.
- [13] YIN L, XIE J. Multi-feature-scale fusion temporal convolution networks for metal temperature forecasting of ultra-supercritical coal-fired power plant reheater tubes[J]. Energy, 2022, 238: 121657.
- [14] HONG F, LONG D, CHEN J, et al. Modeling for the bed temperature 2D-interval prediction of CFB boilers based on long-short term memory network[J]. Energy, 2020, 194: 116733.
- [15] 杨春来, 袁晓磊, 殷喆, 等. 考虑时延特性优化的燃煤锅炉主蒸汽温度预测模型[J]. 热力发电, 2022, 51(8): 124-129.  
YANG Chunlai, YUAN Xiaolei, YIN Zhe, et al. Prediction model of main steam temperature of coal-fired boiler considering time delay characteristic optimization[J]. Thermal Power Generation, 2022, 51(8): 124-129.
- [16] 崔智鹏, 徐婧, 冯征, 等. 数据-机理融合的汽轮机末级排汽焓在线测量[J]. 中国电机工程学报, 2023, 43(4): 1369-1378.  
CUI Zhipeng, XU Jing, FENG Zheng, et al. Data and mechanism based hybrid model of the discharged steam enthalpy for steam turbine[J]. Proceedings of the CSEE, 2023, 43(4): 1369-1378.
- [17] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [18] 金志远, 李胜男, 谭鹏, 等. 基于长短时记忆神经网络的锅炉多参数协同预测模型[J]. 热力发电, 2021, 50(5): 120-126.  
JIN Zhiyuan, LI Shengnan, TAN Peng, et al. Multiparameter collaborative prediction model of boilers based on long-short-term memory neural network[J]. Thermal Power Generation, 2021, 50(5): 120-126.
- [19] 马良玉, 孙佳明. 基于 SDAE 预测模型和改进 SSA 的 NO<sub>x</sub> 排放优化[J]. 中国电机工程学报, 2022, 42(14): 5194-5201.  
MA Liangyu, SUN Jiaming. NO<sub>x</sub> emission optimization based on SDAE prediction model and improved SSA[J]. Proceedings of the CSEE, 2022, 42(14): 5194-5201.
- [20] 国洪立, 陈时熠, 唐寅, 等. 基于 PCA-SSA-LSTM 的余热锅炉状态监测模型[J/OL]. 热力发电. [2023-07-07]. <https://doi.org/10.19666/j.rlfd202212289>.  
GUO Hongli, CHEN Shiyi, TANG Yin, et al. Condition monitoring model of HRSG based on PCA-SSA-LSTM[J/OL]. Thermal Power Generation. [2023-07-07]. <https://doi.org/10.19666/j.rlfd202212289>.

(责任编辑 杜亚勤)