

DOI:10.3969/j.issn.2097-0706.2022.03.009

# 基于人工智能的锅炉受热面管壁温度预测

Prediction on tube wall temperatures of boiler heating surfaces based on artificial intelligence

闫新春<sup>1</sup>, 曹欢<sup>1</sup>, 华云鹏<sup>2\*</sup>  
YAN Xinchun<sup>1</sup>, CAO Huan<sup>1</sup>, HUA Yunpeng<sup>2\*</sup>

(1.河北涿州京源热电有限责任公司,河北涿州 072750; 2.华北电力大学 能源与动力工程学院,北京 102206)

(1.Hebei Zhuozhou Jingyuan Thermal Power Company Limited, Zhuozhou 072750, China; 2.School of Energy and Power Engineering, North China Electric Power University, Beijing 102206, China)

**摘要:**为准确预测锅炉过热器的出口壁温,对某超临界机组受热面出口温度的影响因素进行分析,利用灰色关联分析法得到各影响因素与壁面金属温度的关联度,选取关联度大于 0.7 的 10 个变量作为反向传播(BP)神经网络的输入变量;针对火电厂数据样本的变化特征,通过滑动窗口数据判断,提取多个稳定负荷区段并对区段内的多个输入变量进行聚类,得到清洗后的数据样本;然后通过长短期记忆(LSTM)神经网络方法构建壁面金属温度的预测模型。以某 350 MW 等级超临界锅炉过热器管壁温度为预测对象,预测值与实际测量值的最大误差为 4.9℃,证明了该模型的有效性。

**关键词:**人工智能;长短期记忆神经网络;反向传播神经网络;灰色关联分析法;锅炉;过热器;超温;预测模型

**中图分类号:**TK 172.4 **文献标志码:**A **文章编号:**2097-0706(2022)03-0058-05

**Abstract:** In order to accurately predict the wall temperature of a boiler superheater at its outlet, the influencing factors for the heating surface temperature of the supercritical unit are analyzed. Then, according to the gray correlation analysis on the correlation degree between the influencing factors and metal wall temperature through, ten variables with correlation degree over 0.7 are chosen as the training samples. According to the variation characteristics of the data samples from the thermal power plant, through sliding window data judgment, multiple input variables in the extracted stable load sections are clustered to obtain cleaned data samples. The prediction model of the metal wall temperature is constructed through LSTM neural network. Making prediction on the heating surface temperature of a 350 MW supercritical unit, the maximum error between the predicted result and the measured value is 4.9℃, which proves the effectiveness of the model.

**Keywords:** AI; LSTM; BP neural network; gray correlation analysis; boiler; superheater; overheating; prediction model

## 0 引言

从目前国内投运的超(超)临界机组锅炉运行情况看,受热面的爆管事故较为突出<sup>[1-2]</sup>,而爆管事故大多与运行过程中受热面管道超温有关。受热面超温运行会大幅度降低耐热材料的许用应力和蠕变寿命,结合负荷变动、煤种差异、腐蚀等因素,最终导致受热面泄漏<sup>[3-6]</sup>。为了监测受热面超温情况,燃煤锅炉受热面出口的炉外管圈上均设有管壁温度测点,通过设置合理的报警值来对锅炉的运行进行预警。但仅依靠超温报警的监控方式,无法对锅炉的长期壁温变化趋势进行判断与分析,无法掌握运行中的受热面健康状况。因此,如何建立较为

准确的过热器管壁温预测方法及预测模型,分析预测值与实际运行值的偏差,对于保证锅炉受热面安全运行、提高受热面的使用寿命尤为重要。

目前,传统的壁温计算还是基于前苏联热力计算标准,标准中使用了大量的经验公式及数据,导致工况变化时的壁温计算误差相对较大<sup>[7-9]</sup>。更多学者为了得到更为准确的炉内烟气场及温度场分布情况,开始利用有限元数值模拟的方法,但有限元计算时锅炉屏区传热的模拟还没有十分理想的仿真方法<sup>[10]</sup>。随着人工智能技术的发展,工业设备状态分析与诊断技术得到了快速发展,Dhanuskodia等<sup>[11]</sup>在试验数据的基础上,建立了水冷壁壁温和流体温度的人工神经网络模型。金秀章等<sup>[12]</sup>提出了基于最小二乘支持向量机的锅炉炉膛温度模型。Chang等<sup>[13]</sup>提出了基于人工神经网络的超临界水传热预测模型。

在对火电机组中具有高度耦合、大惯性和大延迟特性热力设备进行状态分析时,神经网络方法得到了广泛应用。但火电机组的运行需要根据电网的负荷进行动态调整,机组运行总是处于“过渡—稳定—过渡”的循环状态,当机组处于过渡状态时,锅炉内部流场的扰动会使监测运行的传感器数值剧烈波动,采集得到的数据质量较差。因此,作为训练模型的输入样本应尽量选择稳定负荷数据。数据的稳态检测问题由Narasimhan等<sup>[14]</sup>于20世纪80年代提出,尽管稳态检测方法的应用有助于提高实际生产的安全性和高效性,但目前仅有为数不多的检测方法被提出并应用到实际生产中<sup>[15-18]</sup>。

本文通过大数据方法,对某350 MW超临界机组的运行数据进行清洗,得到高质量输入样本数据,利用长短期记忆(LSTM)神经网络方法对样本数据进行学习和训练,建立锅炉过热器壁温预测模型,最后通过预测数据与实际运行数据的偏差阈值来判断管道的运行异常。对于锅炉受热面的安全运行具有一定的参考价值。

## 1 壁温预测模型的建立

火电厂锅炉是一个多参量高度耦合的复杂系统,影响锅炉受热面壁温的因素众多,不同的参数对壁温的影响程度也不一样。合理的壁温预测模型建立的前提是可靠的模型训练样本,对于电站锅炉来说,可靠的样本数据应满足以下2点:(1)选取样本需要和锅炉壁温具有高度相关性;(2)样本数据中不应包含对壁温具有高度干扰的运行参数,尤其是吹灰器运行时对应的受热面壁温数据。

### 1.1 壁温影响因素分析

锅炉过热器爆管大多发生在屏式过热器、高温过热器和高温再热器上<sup>[7]</sup>,尤其是高温过热器以及高温再热器,运行环境最为恶劣。从机理上看,影响壁温的主要因素包括烟气侧吸热偏差、蒸汽侧流量偏差以及结构偏差。以某350 MW机组为例,锅炉为前后墙对冲形式,影响烟气侧吸热量的主要因素共10个,包括总给煤量、炉膛总风量、二次风调节阀位(A—E层)、燃尽风调节阀位(前墙和后墙)、尾部烟气挡板调节阀位;影响蒸汽侧流量的主要因素共6个,有主蒸汽焓值(通过压力及温度计算得到)、流量、过热器一/二级减温水焓值及流量;锅炉运行状态的影响因素共5个,包括风煤比、水煤比、风水比、发电机有功功率,总计21个变量(针对某个具体受热面,如本文的某级过热器,取以上变量中的19个变量)。但是,在建立预测模型时,过多的变量会使得神经网络结构过于复杂,同时会影响网络的收

敛速度,因此有必要对所选样本数据进行分析,提取对壁温影响较大的相关变量作为模型的输入变量。

### 1.2 稳态历史数据筛选

输入样本的数据质量对训练模型的可靠性至关重要,本文在对数据进行稳定判断时采用张尚志等<sup>[19]</sup>提出的滑动判别算法。滑动判别算法是基于寻找时间序列稳态段而设计的,通过逐点遍历的方法,沿时间维度滑动,判别各点数据是否处于稳态。设有一维向量 $X$

$$X = [x_1, x_2, x_a, \dots, x_n], \quad (1)$$

同时初始化一维权重向量 $W$

$$W = [w_1, w_2, w_3, \dots, w_n] = [0, 0, 0, \dots, 0], \quad (2)$$

其各项与向量 $X$ 一一对应,用于记录 $X$ 的每个元素是否被判断为稳态。

对于 $X$ 中的元素 $x_i$ ,如果

$$\left| \frac{x_{i-H} + x_{i-(H-1)} + x_{i-(H-2)} + \dots + x_i}{x_i + x_{i+1} + x_{i+2} + \dots + x_{i+H}} - 1 \right| < K, \quad (3)$$

则认为 $x_i$ 为非稳态数据,反之则认为其是稳态数据(其中: $H$ 为滑动窗口宽度; $K$ 为窗口中数据偏离比例)。当 $x_i$ 被判断为非稳态点时,数据点 $x_{i-H} \sim x_{i+H}$ 所对应的权重向量 $W$ 元素分别加1。向量 $X$ 中的所有元素都经过稳态判断后,对权重向量 $W$ 中的元素进行判断,当其大于某一阈值时,则其对应的向量 $X$ 中的元素 $x_i$ 为非稳态点,反之为稳态点。对某350 MW机组的历史负荷曲线进行数据筛选,设 $K$ 为5%,滑动窗口宽为10 min;对周期为1 min的原始数据进行筛选,部分结果如图1所示。




图1 稳定负荷判断

Fig. 1 Steady load judgment

### 1.3 输入变量筛选

本文利用灰色关联分析法对模型的多个输入变量进行降维处理,其核心是按照一定规则确立随时间变化的母序列,把各个评估对象随时间的变化作为子序列,求各个子序列与母序列的相关程度,依照相关性大小得出结论。

设 $X_0 = \{x_0(t) | t = 1, 2, 3, \dots, n\}$ 为参考序列,设有 $m$ 个比较序列 $X_m$ ,可写为

$$X_u = \begin{bmatrix} x_1(1) & x_1(2) & \cdots & x_1(n) \\ x_2(1) & x_2(2) & \cdots & x_2(n) \\ \vdots & \vdots & \ddots & \vdots \\ x_m(1) & x_m(2) & \cdots & x_m(n) \end{bmatrix}, \quad (4)$$

则  $t$  时刻输入序列  $X_0$  与输出序列  $X_u$  的关联系数为

$$\xi_u(t) = \frac{\Delta \min + \rho \Delta \max}{\Delta u(t) + \rho \Delta \max}, \quad (5)$$

$$u = 1, 2, \cdots, m; t = 1, 2, \cdots, n,$$

式中:  $\Delta \min = \min_u \min_v |x_0(t) - x_u(t)|$  为两级最小差;

$\Delta \max = \max_u \max_v |x_0(t) - x_u(t)|$  为两级最大差;

$\Delta u(t) = |x_0(t) - x_u(t)|$ ;  $\rho$  为分辨系数, 一般取值 0.5。

则输入序列与输出序列的关联度为

$$R_u = \frac{1}{n} \sum_{t=1}^n \xi_u(t). \quad (6)$$

对所选 19 个参数进行关联度分析, 结果见表 1。

设定关联度阈值为 0.70, 得到与出口壁面温度具有强相关的 10 个变量作为神经网络输入参数。

表 1 受热面出口管壁温度关联度

Table 1 Analysis on the correlation degree with tube wall temperature at the heater outlet

| 参数          | 关联度   |
|-------------|-------|
| 主蒸汽温度       | 0.902 |
| 主蒸汽流量       | 0.814 |
| 主蒸汽压力       | 0.790 |
| 省煤器入口流量     | 0.892 |
| 省煤器入口温度     | 0.738 |
| 发电机有功功率     | 0.792 |
| 入炉总煤量       | 0.755 |
| 入炉总风量       | 0.705 |
| 一级减温器入口蒸汽温度 | 0.772 |
| 二级减温器入口蒸汽温度 | 0.790 |
| 一级减温器后蒸汽温度  | 0.605 |
| 二级减温器后蒸汽温度  | 0.625 |
| 一级减温水流量     | 0.621 |
| 一级减温水温度     | 0.582 |
| 二级减温水流量     | 0.669 |
| 二级减温水温度     | 0.682 |
| 风煤比         | 0.455 |
| 风水比         | 0.565 |
| 水煤比         | 0.505 |

#### 1.4 反向传播(BP)神经网络预测模型

BP 算法是一种最有效的多层神经网络学习方法, 其主要特点是信号前向传递, 而误差后向传播, 通过不断调节网络权重值, 使得网络的最终输出与期望输出尽可能接近, 以达到训练的目的<sup>[13]</sup>。通常一个多层神经网络由  $L$  层神经元组成, 第 1 层为输入层, 最后一层(第  $L$  层)为输出层, 其他各层均为隐含层, 如图 2 所示。




图 2 BP神经网络传播关系

Fig. 2 BP neural network propagation

设  $w_{ij}^l$  为从  $l-1$  层第  $j$  个神经元与  $l$  层第  $i$  个神经元之间的连接权重;  $b_i^l$  为第  $l$  层第  $i$  个神经元的偏置, 那么第  $l$  层第  $i$  个神经元的输出为

$$h_i^l = f(n_i^l), \quad (7)$$

$$n_i^l = \sum_{j=1}^{s_{l-1}} w_{ij}^l h_j^{l-1} + b_i^l. \quad (8)$$

式中:  $n_i^l$  为第  $l$  层第  $i$  个神经元的输入;  $s_l$  为第  $l$  层神经元的个数;  $f(\cdot)$  为神经元的激活函数。

本文采用 3 层神经网络拓扑结构, 如图 3 所示。输入层变量为表 1 中关联度大于 0.7 的 10 个变量; 隐含层节点数根据柯尔莫哥洛夫(Kolmogorov)定理选取为 21 个; 输出层为高温过热器出口处管壁温度。

## 2 模型验证与分析

### 2.1 样本数据处理

本文以某 350 MW 等级超临界锅炉过热器第 10 屏和第 35 屏的管壁温度为预测对象。选取表 1 中关联度大于 0.7 的 10 个变量作为神经网络输入端, 构建图 3 所示的神经网络。




图 3 BP神经网络模型

Fig. 3 BP neural network model

利用式(3)对图 3 中 10 个输入数据的历史数据进行筛选, 筛选结构见表 2。

表 2 聚类处理后的神经网络训练样本  
Table 2 Neural network training samples after clustering

| 项目       |               | 时间(2020年)               |                         |                         |                         |                         |       |                         |                         |                              |       |
|----------|---------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------|-------------------------|-------------------------|------------------------------|-------|
|          |               | 06-24 T 02:<br>25—05:59 | 06-28 T 01:<br>38—05:06 | 06-29 T 23:<br>17—23:43 | 07-02 T 02:<br>16—06:48 | 07-12 T 02:<br>01—08:01 | ...   | 07-15 T 20:<br>11—20:19 | 07-17 T 09:<br>05—09:23 | 07-17 T 23:<br>37—18 T 00:03 |       |
| 输入<br>变量 | 有功功率          | 175.0                   | 174.1                   | 172.2                   | 178.2                   | 177.1                   | ...   | 309.2                   | 309.1                   | 176.0                        |       |
|          | 主蒸汽流量         | 525.4                   | 524.7                   | 510.1                   | 535.3                   | 532.3                   | ...   | 960.0                   | 948.4                   | 519.8                        |       |
|          | 主蒸汽压力         | 14.1                    | 14.1                    | 14.2                    | 14.3                    | 14.2                    | ...   | 24.1                    | 24.3                    | 14.3                         |       |
|          | 主蒸汽温度         | 562.3                   | 563.4                   | 561.8                   | 563.3                   | 561.3                   | ...   | 561.2                   | 560.3                   | 564.6                        |       |
|          | 给水流量          | 494.3                   | 485.7                   | 479.2                   | 495.2                   | 520.1                   | ...   | 974.9                   | 944.1                   | 491.1                        |       |
|          | 给水温度          | 281.0                   | 280.2                   | 282.1                   | 283.5                   | 277.2                   | ...   | 305.4                   | 308.9                   | 281.3                        |       |
|          | 左侧一级喷水        | 减温前温度                   | 426.6                   | 437.7                   | 462.7                   | 431.6                   | 418.0 | ...                     | 436.0                   | 448.3                        | 438.5 |
|          |               | 减温后温度                   | 412.1                   | 407.7                   | 425.9                   | 411.4                   | 412.7 | ...                     | 433.8                   | 443.8                        | 418.7 |
|          | 右侧一级喷水        | 减温前温度                   | 452.3                   | 448.8                   | 426.0                   | 448.5                   | 431.3 | ...                     | 445.9                   | 445.0                        | 433.9 |
|          |               | 减温后温度                   | 419.0                   | 418.1                   | 415.2                   | 418.5                   | 419.6 | ...                     | 434.5                   | 435.3                        | 415.1 |
|          | 左侧二级喷水        | 减温前温度                   | 482.7                   | 483.7                   | 495.2                   | 483.9                   | 478.0 | ...                     | 474.7                   | 491.0                        | 489.3 |
|          |               | 减温后温度                   | 457.0                   | 449.9                   | 453.7                   | 451.3                   | 459.7 | ...                     | 463.8                   | 472.8                        | 462.9 |
|          | 右侧二级喷水        | 减温前温度                   | 495.3                   | 493.6                   | 484.0                   | 493.7                   | 481.1 | ...                     | 483.2                   | 482.2                        | 481.5 |
|          |               | 减温后温度                   | 458.7                   | 449.8                   | 460.3                   | 452.0                   | 459.7 | ...                     | 477.6                   | 475.6                        | 450.5 |
| 输出<br>变量 | 末级过热器 1307 壁温 | 580.1                   | 579.2                   | 572.1                   | 583.2                   | 574.0                   | ...   | 568.7                   | 572.6                   | 579.7                        |       |
|          | 末级过热器 3507 壁温 | 573.6                   | 576.4                   | 581.0                   | 572.9                   | 575.9                   | ...   | 570.3                   | 567.5                   | 572.7                        |       |

由表 2 可以看出,每个时间段的负荷值相差不大,最大与最小负荷差值小于 5 MW,对数据进行聚类处理,得到每个时段数据的聚类值。共得到样本数据 1 928 条,其中 80% 的数据量作为训练样本,20% 数据作为测试样本。

2.2 预测及分析

在确定输入层参数并进行数据清洗和聚类分析的基础上,通过引入 Keras 开源深度学习库,实现 LSTM 神经网络的搭建<sup>[10,20]</sup>。采用均方根误差和平均绝对误差作为模型的评价指标。训练集和验证集的损失值变化趋势如图 4 所示。通过图 4 可看出,模型经过 20 次训练后损失值大幅降低,在第 20~35 次训练阶段损失函数基本保持平稳,基本上在 15 次训练后即可达到满意的效果。




图 4 损失值变化趋势

Fig. 4 Variation of loss value

利用训练好的模型,对过热器第 35 屏第 7 根管的温度进行仿真,仿真结果如 5 图所示。由图 5 可

以看出,本文模型可以较好地模拟出金属壁温的变化趋势,其中最大误差为 4.9℃,满足工程需要。




图 5 测量值与仿真值对比

Fig. 5 Comparison of measured values and predicted values

3 结论

本文通过稳态负荷筛选、输入参量相关度分析和聚类的方法对输入样本进行处理,保证了样本数据的可靠性,进而利用 LSTM 神经网络方法建立过热器壁面温度预测模型,可以对过热器壁温进行快速准确的预测。(1)通过相关性可大大减少输入变量,并且保证一定的预测精度。(2)运行过程中的参数扰动对火电厂样本数据的质量有重要影响,需要针对火电厂数据的特征进行稳定负荷筛选。

在本文的预测模型的基础上,可对运行参数进行动态监测,如果测量值和预测值出现持续偏差,可作为受热面内部传热特性变化的依据,进而对受热面的可靠性进行评价。

## 参考文献:

- [1] 饶庆平. 超临界锅炉超温爆管的防范[J]. 电力与电工, 2010(4): 12-15.
- [2] 黄兴德, 周新雅, 游喆, 等. 超(超)临界锅炉高温受热面蒸汽氧化皮的生长与剥落特性[J]. 动力工程, 2009, 29(6): 602-608.
- HUANG Xingde, ZHOU Xinya, YOU Zhe, et al. Oxide scale growth and exfoliation behavior on high temperature heat-absorbing surface exposed to steam for supercritical (ultrasupercritical) boilers [J]. Journal of Power Engineering, 2009, 29(6): 602-608.
- [3] 穆岱. 蒸汽侧氧化膜对电站锅炉管道壁温及测温误差的影响[D]. 北京: 华北电力大学, 2014: 1-8.
- [4] 伍健伟, 吕杰, 金光亮, 等. 1 000 MW 机组锅炉受热面超温原因分析及对策[J]. 东北电力技术, 2012, 33(9): 18-20.
- WU Jianwei, LYU Jie, JIN Guangliang, et al. Analysis and countermeasures on over-heating issues of boiler heating surface in 1 000 MW ultra supercritical unit [J]. Northeast Electric Power Technology, 2012, 33(9): 18-20.
- [5] 王学礼. 1 000 MW 超超临界锅炉过热器爆管原因分析及防范措施[J]. 华电技术, 2019, 41(7): 70-72.
- WANG Xueli. Reasons analysis for tube blasting and preventive measures for superheater of 1 000 MW supercritical boiler [J]. Huadian Technology, 2019, 41(7): 70-72.
- [6] 温志强, 朱宪然, 任金磊. 600 MW 亚临界机组锅炉内高温受热面壁温实测研究[J]. 电站系统工程, 2013, 29(4): 26-28.
- WEN Zhiqiang, ZHU Xianran, REN Jinlei. Measurement study for wall temperature of high temperature surfaces in a 600 MW subcritical boiler [J]. Power System Engineering, 2013, 29(4): 26-28.
- [7] 初云涛, 周怀春, 梁倩. 两类过热器壁温分布特性的仿真研究[J]. 动力工程, 2008, 28(1): 40-44, 83.
- CHU Yuntao, ZHOU Huaichun, LIANG Qian. Simulation research on the wall temperature distribution characteristics of two types of superheater [J]. Journal of Power Engineering, 2008, 28(1): 40-44, 83.
- [8] 郭涛. 大型电站锅炉高温受热面热偏差分析研究[D]. 北京: 华北电力大学, 2014: 6-8.
- [9] 杨润红. 大容量燃煤电站锅炉热力计算分析研究[D]. 北京: 北京交通大学, 2007: 4-5.
- [10] TROJAN M, TALER D. Thermal simulation of superheaters taking into account the processes occurring on the side of the steam and flue gas [J]. Fuel, 2015, 150: 75-87.
- [11] DHANUSKODIA R, KALIAPPANA R, SURESHA S, et al. Artificial Neural Networks model for predicting wall temperature of supercritical boilers [J]. Applied Thermal Engineering, 2015, 90: 749-753.
- [12] 金秀章, 魏琳, 王真. 基于最小二乘支持向量机的锅炉炉膛温度在线预测[J]. 热力发电, 2016, 45(7): 93-97.
- [13] CHANG W, CHU X, FATIMA BSFA, et al. Heat transfer prediction of supercritical water with Artificial Neural Networks [J]. Applied Thermal Engineering, 2018, 131: 815-824.
- [14] NARASIMHAN S, MAH R S H, TAMHANE A C, et al. A composite statistical test for detecting changes of steady states [J]. AIChE Journal, 1986, 32(9): 1409-1418.
- [15] 韩驰. 超(超)临界火电机组炉膛受热面金属壁温预测及监测系统[D]. 吉林: 东北电力大学, 2020.
- [16] 何彪. 基于历史数据的电站锅炉故障检测及动态建模 [D]. 武汉: 华中科技大学, 2018.
- [17] 韩旭东. 基于数据驱动的火电机组高压加热系统异常检测研究[J]. 华电技术, 2021, 43(8): 67-73.
- HAN Xudong. Data-driven based research on anomaly detection for high-pressure heaters in thermal power units [J]. Huadian Technology, 2021, 43(8): 67-73.
- [18] 刘吉臻, 高萌, 吕游, 等. 过程运行数据的稳态检测方法综述[J]. 仪器仪表学报, 2013, 34(8): 1739-1748.
- LIU Jizhen, GAO Meng, LYU You, et al. Overview on the steady-state detection methods of process operating data [J]. Chinese Journal of Scientific Instrument, 2013, 34(8): 1739-1748.
- [19] 张尚志, 谭鹏, 何彪, 等. 基于滑动判别算法的低 $\text{NO}_x$ 燃烧优化分析[J]. 热力发电, 2016, 45(5): 33-40.
- ZHANG Shangzhi, TAN Peng, HE Biao, et al. Combustion optimization for low  $\text{NO}_x$ -emission based on slippage distinguishing algorithm [J]. Thermal Power Generation, 2016, 45(5): 33-40.
- [20] 崔博洋, 王永林, 王云, 等. 基于长短期记忆神经网络的吸收塔 pH 值预测模型[J]. 华电技术, 2020, 42(9): 32-36.
- CUI Boyang, WANG Yonglin, WANG Yun, et al. Prediction model for the pH value of absorption tower slurry based on LSTM neural networks [J]. Huadian Technology, 2020, 42(9): 32-36.

(本文责编: 刘芳)

## 作者简介:

闫新春(1978), 男, 工程师, 从事厂内金属技术监督、特种设备管理工作, 171457409@qq.com;

曹欢(1992), 男, 工程师, 硕士, 从事火力发电热控技术管理、优化控制工作, caohuanemail@163.com;

华云鹏\*(1998), 男, 在读硕士研究生, 从事深度学习方面的研究, 2909108339@qq.com.

\*为通信作者。