

# 基于混合神经网络的锅炉燃烧设备故障智能检测方法

崔小军<sup>1</sup>, 徐光平<sup>2</sup>, 徐俊<sup>2</sup>, 杨文明<sup>2</sup>

(1.陕西德源府谷能源有限公司, 陕西 榆林 719000;

2.北京中安吉泰科技有限公司, 北京 100089)

**摘要:**为提高锅炉燃烧设备的稳定性和生产效率,确保工业生产的连续性和高效性,研究基于混合神经网络的锅炉燃烧设备故障智能检测方法。对传感器获取的多种形式锅炉燃烧设备运行数据预处理;提取与设备运行故障相关的关键特征;建立锅炉燃烧设备运行数据的时序处理模型,提出故障检测模型;融合卷积神经网络和长短期记忆网络,通过两者的判断实现故障智能检测。实验结果表明,以火电厂锅炉燃烧设备的历史故障数据作为测试样本,分别标定正常工况以及3种故障状态,所研究方法可以实现不同类型故障的检测,具有应用价值。

**关键词:**混合神经网络;锅炉燃烧设备;故障检测;故障类型

**中图分类号:**TP183;TP277 **文献标识码:**A **文章编号:**1003-7241(2025)09-0044-05

## Intelligent Fault Detection Method for Boiler Combustion Equipment Based on Hybrid Neural Network

CUI Xiaojun<sup>1</sup>, XU Guangping<sup>2</sup>, XU Jun<sup>2</sup>, YANG Wenming<sup>2</sup>

(1. Shaanxi Deyuan Fugu Energy Co., Ltd., Yulin 719000, China;

2. Beijing Zhonganjitai Technology Co., Ltd., Beijing 100089, China)

**Abstract:** In order to improve the stability and production efficiency of boiler combustion equipment and ensure the continuity and efficiency of industrial production, the intelligent fault detection method of boiler combustion equipment based on hybrid neural network is studied. It preprocesses the operation data of various forms of boiler combustion equipment obtained by sensors, extracts the key features related to equipment operation faults. The time sequence processing model of boiler combustion equipment operation data is established, and the fault detection model is proposed. By fusing convolutional neural network and long-term and short-term memory network, intelligent fault detection is realized through the judgment of both. The experimental results show that, taking the historical fault data of boiler combustion equipment in thermal power plant as test samples, the normal working conditions and three fault states are calibrated respectively, and the research method can realize the detection of different types of faults, which has application value.

**Keywords:** hybrid neural network; boiler combustion equipment; fault detection; fault type

## 0 引言

锅炉燃烧设备是工业化发展的重要产物,也是能源转换和供应的核心组件,其稳定运行对于保障工业生产和能源安全具有重要意义。但在实际运行过程中,受多种因素影响,锅炉燃烧设备在应用中会出现不同类型的故障。当故障发生时,不能保证人员和设备的安全,对人员的生命以及厂内经济构成威胁,需要开发高效、准确的锅炉燃烧设备故障智能检测方法,以此保障锅炉燃烧设备生产安全。国内外学者针对这一课题,开展了一系列有效研究,并提出多种研究成果,美国等发达国家主要应用信号处理算法,对锅炉燃烧设备的故障进行检测,如在

文献[1]中提出了基于傅里叶变换,该方法通过傅里叶变换,将时域信号转换为频域信号,实现频率成分变化的分析,最终按照设定的具体判断阈值,检测锅炉燃烧设备故障。但傅里叶变换只能提供全局的频率信息,对于非平稳信号和时变故障特征提取效果不佳。在文献[2]中利用小波分析设计了锅炉燃烧设备故障检测方法,通过小波分析分解多尺度信号,对锅炉燃烧设备的运行特征进行提取,实现不同类型故障检测。但小波分析依赖于分解层数,当选择不当时,无法保证特征提取的全面性,在故障类型判断时存在不足。随着人工智能算法的成熟发展,国内在总结国外先进经验的基础上,学者更多地关注于深度学习在锅炉故障检测中的应用。在文献[3]中通过感知网络提出锅炉燃烧设备故障检测方法,通过建立感

\*基金项目:陕西省国家能源集团科技项目(GSKJ-23-15)

收稿日期:2024-05-08

知网络训练模型,对采集到的运行数据进行预处理和特征提取,实现锅炉燃烧设备的故障分类,完成对其不同故障类型的检测。但感知网络对输入数据的预处理和特征选择要求较高,在数据不完整或者错误的情况下,仅适用于简单模式识别任务,对于复杂的锅炉燃烧设备故障检测可能效果不佳。在文献[4]中以长短时记忆网络设计故障检测方法,该方法在采集锅炉不同运行数据的基础上,通过长短时记忆网络构建训练模型,在参考历史数据的标准下确定模型调整参数,在获取实时数据时,通过训练模型对数据是否存在故障进行判断,然而,长短期记忆网络模型需要大量的数据作为支撑,且对时间序列的要求较高,在参数调整时耗时较多,影响最终故障的检测效率。但神经网络在故障识别中以及故障类型判断中,仍具有显著优势,其中,混合神经网络融合了多种神经网络模型,能够克服单一模型的局限性,为此,探究基于混合神经网络的锅炉燃烧设备故障的智能检测方法,以期为实际应用提供有力支持。

## 1 预处理锅炉燃烧设备运行数据

针对锅炉燃烧设备故障检测,国内外学者进行了广泛研究。美国等发达国家主要应用信号处理算法,如傅里叶变换和小波分析,但这些方法在处理非平稳信号和时变故障特征时存在不足。随着人工智能的发展,深度学习在国内受到关注。感知网络和长短时记忆网络等方法被提出,但它们在数据预处理、特征选择和数据需求方面存在挑战。因此,研究基于混合神经网络的智能检测方法,融合多种模型优势,对锅炉燃烧设备故障检测具有实际应用价值。

锅炉燃烧设备的运行数据由传感器获取,通常以时间序列形式存在,具有一定的连续性,但锅炉燃烧设备在不同时间点中,产生的数据具有多种形式,包含有温度、压力、流量等。对于不同表现形式的运行数据,为实现统一化处理以及后续的故障检测建模,将以时间序列下收集到的数据进行转换,整合为标准的数据集合形式,表示为

$$\mathbf{q} = \left\{ \begin{array}{l} (w_1, e_1), (w_2, e_2), \dots, (w_r, e_r) \\ (w_1, t_1), (w_2, t_2), \dots, (w_r, t_r) \end{array} \right\} \quad (1)$$

式中,  $\mathbf{q}$  为时间序列下的数据样本标准化矩阵;  $w_r$  为第  $r$  个数据样本的特征;  $t_i, e_i$  分别为第  $i$  个数据样本对应的故障和正常状态运行数据,  $i$  取值为  $[1, r]$ 。

对于不同节点中获取的锅炉燃烧设备运行数据,由于其为传感器获取形式,会存在一定的噪声影响,导致数据在获取时产生丢失和空白以及异常问题,需要对其进

行清洗、去噪以及标准化处理,步骤如下:

$$y_{3\alpha} = \frac{|w_r - w_r''|}{w_r(\alpha)} \quad (2)$$

式(2)为数据清洗步骤,主要是对锅炉燃烧运行数据中的异常、重复、缺失情况进行处理。 $y_{3\alpha}$ 为清洗结果, $3\alpha$ 为清洗原则,即  $y_{3\alpha} > 3$  时,表示数据样本  $w_r$  为异常值;  $w_r''$  为数据样本均值;  $w_r(\alpha)$  为数据样本的标准差。

$$u_i(o, p) = \frac{1}{\sqrt{o}} \int_{-\infty}^{\infty} s(w_r) \beta\left(\frac{w_r - p}{o}\right) w_r \quad (3)$$

式(3)为采用小波去噪方式的数据去噪过程计算方式。 $u_i(o, p)$  为小波变换系数,  $o$  为尺度参数,  $p$  为平移参数;  $s(w_r)$  为数据样本的原始信号数据;  $\beta(\cdot)$  为小波去噪函数<sup>[5]</sup>。

$$w_r' = \frac{w_r - \min w_r}{\max w_r - \min w_r} \quad (4)$$

式(4)为数据标准化的处理过程,主要为消除数据中的量纲差异,以最大最小标准化形式处理锅炉燃烧设备运行数据。 $w_r'$  为数据的最小-最大标准化结果;  $\min w_r$  为  $w_r$  的最小值;  $\max w_r$  为  $w_r$  的最大值。

经过对原始数据样本的去噪以及标准化清洗,通过传感器获取的锅炉燃烧设备的运行数据,其内部不存在异常值和重复值,且具有相同的尺度量纲,可以为后续的数据特征提取提供准确依据,为此,采用卷积神经网络提出数据中与故障相关的关键信息。

## 2 卷积神经网络理论提取锅炉故障关键特征

在预处理锅炉燃烧设备的运行数据后,为实现具体故障类型的检测,需要对数据中存在的与故障相关的特征进行提取,采用卷积神经网络理论建立提取模型,在数据的滑动卷积运算下,分类特征并获取数据中的故障特征<sup>[6]</sup>。过程如下:

$$\begin{cases} d^1 = g * (w_r') + j \\ d^2 = g^1 * (w_r')^1 + j^1 \\ \vdots \\ d^f = g^{f-1} * (w_r')^{f-1} + j^{f-1} \\ d^{f+1} = g^f * (w_r')^f + j^f \end{cases} \quad (5)$$

式(5)为卷积层的运算过程,  $d^1, d^2, d^f, d^{f+1}$  分别为第1、2、 $f, f+1$  层的卷积层的输出值,  $f$  为卷积层层数;  $g^f$  为第  $f$  层的卷积核权重; “\*” 为卷积运算符号;  $(w_r')^f$  为第  $f$  层的标准化数据输入值;  $j^f$  为  $f$  层的偏置项。

$$\begin{cases} k^1 = \text{koop}_{\max}(d^1) \\ k^2 = \text{koop}_{\max}(d^2) \\ \vdots \\ k^f = \text{koop}_{\max}(d^f) \\ k^{f+1} = \text{koop}_{\max}(d^{f+1}) \end{cases} \quad (6)$$

式(6)为池化层运算过程,  $k_1, k_2, k^f, k^{f+1}$ 各自为第1、2、 $f$ 、 $f+1$ 层的池化层的输出<sup>[7]</sup>;  $\text{koop}_{\max}(\cdot)$ 为对应卷积层输出值的池化函数,采用最大池化标准。

基于上述构建的卷积层与池化层,受偏置项和权重的影响,在全连接层的特征学习中,采用前向和反向传播理论,不断调整两组参数,实现特征的最终提取,如下:

$$\begin{cases} (w_r')^1 = \text{rule}(d^1) \\ (w_r')^2 = \text{rule}(d^2) \\ \vdots \\ (w_r')^f = \text{rule}(d^f) \\ (w_r')^{f+1} = \text{rule}(d^{f+1}) \end{cases} \quad (7)$$

式(7)为激活过程。  $\text{rule}(\cdot)$ 为激活函数。

$$\begin{cases} \Delta g^f = \frac{\text{loss}(w_r')}{g^f} \\ \Delta j^f = \frac{\text{loss}(w_r')}{j^f} \end{cases} \quad (8)$$

式(8)为梯度计算过程。  $\Delta g^f$ 为第 $f$ 层的  $g^f$ 梯度;  $\Delta j^f$ 为  $j^f$ 的梯度;  $\text{loss}(\cdot)$ 为损失函数。

$$k = \text{CNN}_x(w_r'; \Delta g^f, \Delta j^f) \quad (9)$$

式(9)为特征提取过程。  $k$ 为提取的特征数据;  $\text{CNN}_x$ 为卷积神经网络模型。

通过构建的卷积神经网络模型,对预处理的运行数据进行特征学习,在权重与偏置项的梯度下降优化过程中,实现关键特征的表示,以此建立锅炉燃烧设备的运行数据时序模型。

### 3 长短期记忆网络结合特征建立时序模型

由于锅炉设备的运行数据,以传感器装置获取,并展现为时间节点的形式,为此,采用长短期记忆网络融合故障特征,建立运行数据的时序模型。通过长短期记忆网络建立时序模型,能够获取数据中故障特征与故障发生时间的长期依赖关系,以此更加准确地描述锅炉燃烧设备的运行状态<sup>[8-11]</sup>。长短期记忆网络是一种特殊的循环神经网络,模型建立过程为

$$\begin{cases} z_x = \text{sigmoid}(c_z[\phi_{x-1}, \{k\}_x] + \varepsilon_z) \\ b_x = \text{sigmoid}(c_b[\phi_{x-1}, \{k\}_x] + \varepsilon_b) \\ n_x = \text{sigmoid}(c_n[\phi_{x-1}, \{k\}_x] + \varepsilon_n) \\ m_x = z_x m_{x-1} + b_x \tanh(c_m[\phi_{x-1}, \{k\}_x] + \varepsilon_m) \\ \phi_x = n_x \tanh(m_x) \end{cases} \quad (10)$$

式中,  $z_x, b_x, n_x$ 为  $x$ 下的遗忘门、输入门、输出门对应的输出值;  $x-1, x$ 为上一时刻与当前时刻;  $m_{x-1}, m_x$ 分别为上一时刻和当前时刻的记忆单元状态的数据值;  $\text{sigmoid}(\cdot)$ 为映射函数,用于输出值的映射;  $c_z, c_b, c_n, \varepsilon_m$ 为  $z_x, b_x, n_x, m_x$ 为对应的权重;  $\phi_{x-1}$ 为  $x-1$ 的隐藏状态输入值;  $\{k\}_x$ 为当前时刻  $x$ 下的提取特征集合的输入值;  $\varepsilon_z, \varepsilon_b, \varepsilon_n, c_m$ 为  $z_x, b_x, n_x, m_x$ 为对应的偏置项。

在门控机制和记忆单元的计算过程中,长短期记忆网络能够获取时间序列下数据的关系,其中,  $z_x$ 决定了  $m_{x-1}$ 的关键信息保留,  $b_x$ 决定了  $m_x$ 中的信息写入,  $n_x$ 决定了最终的信息输出。通过最终的输出信息,可以得到相应的特征向量,包含有设备的运行状态信息,以此构建长短期记忆网络序列模型,判断锅炉燃烧设备的运行状态,步骤为:

$$\begin{aligned} \text{lstm}(\phi) &= \text{lstm}(k = \text{CNN}_x(w_r'; \Delta g^f, \Delta j^f)) \\ &= \text{Exterct}_x(w_r') \end{aligned} \quad (11)$$

式中,  $\text{lstm}(\cdot)$ 为长短期记忆网络序列模型;  $\text{lstm}(\phi)$ 为通过长短期记忆网络与从预处理后数据中提取到的特征的隐藏状态运行数据;  $\text{Exterct}_x(\cdot)$ 为融合函数。

$$W^m = \text{presccit}(\text{lstm}(\phi)) \quad (12)$$

式中,  $W^m$ 为设备运行状态时序模型预测结果;  $\text{presccit}(\cdot)$ 为预测函数。

根据长短期记忆网络建立设备的运行状态时序模型,实现对燃烧锅炉状态的评估,在此基础上,结合长短期记忆网络和卷积神经网络,对实时产生的运行数据进行判断,完成对锅炉燃烧设备的故障检测。

### 4 混合神经网络智能检测锅炉燃烧设备故障

此次结合两个神经网络构成混合神经网络模型,卷积神经网络主要应用于故障特征的提取,长短期记忆神经网络用于时间序列数据中的长期关系获取,通过构建的预测函数,在获取锅炉燃烧设备实时运行数据时,还需在模型中引入状态预测概率,以此判断设备在当前时刻所处的状态。将概率分布向量表示为  $\mathbf{A} = [A_1, A_2, \dots, A_s]$ ,  $A_s$ 表示设备处于第  $S$ 种状态的概率,为保证对设备状态预测的准确性,需要设定预测概率的置信区间,以及故障

判断的标准阈值,分别为

$$P(A_H) = \frac{A_H(1-A_H)}{1 + \sum_{G=1}^S A_G} \quad (13)$$

式(13)为设备状态预测概率计算过程, $P(A_H)$ 为预测概率; $A_H$ 和 $A_G$ 分别表示设备处于第 $H$ 和第 $G$ 种状态下的概率值; $S$ 表示设备状态种类总数目。

$$L_H = [A_H - 1.96 \times FG(A_H), A_H + 1.96 \times \sqrt{P(A_H)}] \quad (14)$$

式(14)设备状态预测概率的置信区间计算过程, $L_H$ 为第 $H$ 种状态下计算得到的置信区间。

$$\begin{cases} A_H'' = \frac{1}{S} \sum_{H=1}^S A_H \\ A_H''' = \sqrt{\frac{1}{S} \sum_{H=1}^S (A_H - \frac{3}{4} L_H)^2} \\ K = \frac{3}{4} A_H'' + Z \left( \frac{1}{4} A_H''' + J \right) \end{cases} \quad (15)$$

式(15)为故障判断过程各指标的具体计算。 $A_H''$ 为 $A_H$ 均值; $A_H'''$ 为 $A_H$ 标准差; $K$ 为阈值; $Z$ 为置信水平选择的常数; $J$ 为误差项。

$$\begin{cases} P(A_H) \geq K, C_V \in t_r \\ P(A_H) < K, C_V \in e_r \end{cases} \quad (16)$$

式(16)为由设备状态预测概率对故障进行判断的具体阈值设定, $C_V$ 为实时运行数据。在对锅炉燃烧设备故障的预测过程中,将预测概率与判断阈值进行比较,当 $P(A_H)$ 大于等于阈值时,表示 $C_V$ 为故障状态,反之则为正常状态<sup>[12]</sup>。

至此,本文基于混合神经网络实现锅炉燃烧设备故障智能检测方法设计。

## 5 实验测试分析

为验证提出的基于混合神经网络的故障智能检测效果,证明其可以有效检测锅炉燃烧设备故障检测,采用对比测试方法完成论证。分别选择文献[3]和文献[4]中的方法作为对照组,通过实验室平台中锅炉模拟系统,设定此次测试的数据集合。以火电厂锅炉燃烧设备的历史运行数据为测试样本,共采集970组数据,其中,550组数据在正常工况下获取,剩余数据为发生故障时的样本,分别为:

- (1) 烟道轻微阻塞故障,总计为140组。
- (2) 供油管路滤清器脏污故障,数量为140组。
- (3) 主安全阀少量泄漏故障,采集数量为140组。

按照数据采集的设定标准,将选择的全部样本,分为训练集合和测试集合,训练集合包含670组数据,其中,正常工况数据量为400组,各组故障类型数据均为90组;测试集合包含300组,并将每种类型数据设定为具体的标

签,如下:

- (1) “正常工况”,设定为“M”。
- (2) “烟道轻微阻塞故障”,设定为“N”。
- (3) “供油管路滤清器脏污故障”,设定为“B”。
- (4) “主安全阀少量泄漏故障”,设定为“V”。

根据设计情况,选择20个样本进行具体情况的展示,见表1。

表1 锅炉燃烧设备故障样本数据

编号	炉膛压力/ MPa	炉膛排烟 温度/°C	汽包 温度/°C	汽包 压力/MPa	汽包 水位/mm	标签
1	0.071	381.2	212.8	1.55	735.5	M
2	0.072	382.2	210.6	1.54	734.9	M
3	0.075	382.7	213.1	1.52	736.4	M
4	0.072	382.2	210.6	1.54	734.9	M
5	0.075	382.7	213.1	1.52	736.4	M
6	0.081	382.5	215.4	1.72	731.7	N
7	0.083	383.4	214.2	1.75	732.9	N
8	0.091	383.1	214.8	1.78	731.4	N
9	0.085	383.2	214.5	1.76	732.9	N
10	0.090	383.2	214.6	1.78	731.6	N
11	0.082	373.8	208.3	1.72	752.6	B
12	0.077	373.6	207.4	1.74	754.6	B
13	0.080	373.7	208.2	1.73	752.4	B
14	0.076	373.5	207.2	1.74	754.6	B
15	0.081	373.6	208.4	1.67	740.1	B
16	0.076	380.8	208.4	1.68	710.2	V
17	0.074	383.2	211.2	1.63	722.6	V
18	0.075	383.6	211.8	1.64	724.6	V
19	0.075	383.5	211.5	1.64	723.5	V
20	0.076	383.4	211.6	1.65	7247	V

根据表1中内容所示,针对部分数据样本的展示,将测试集合中的数据归类到不同的状态标签中,并将带有标签的数据样本,通过选择的3组检测方法进行故障判断,验证不同方法的应用效果。由于此次选择的两组传统方法也有深度学习方式,具有同类型对比价值,统计测试结果,见图1。

如图1所示,每组方法对各组样本标签的判断具有差异性,其中,标签“M”的数量为150组,“N”“B”“V”数量为各为50组。对于两组传统方法来看,其诊断效果与所研究方法的诊断效果具有一定差距,文献[3]中方法,对正常工况以及3种故障数据样本,分别出现了16个、4个、6个、6个样本的诊断错误,文献[4]中方法出现了13个、4个、6个、5个样本的诊断错误,而所研究方法在“烟道轻微阻塞故障”“供油管路滤清器脏污故障”检测中不存在误




图1 不同方法对锅炉燃烧设备故障诊断对比

判,仅对于“正常工况”与“主安全阀少量泄漏故障”中出现了2次误判,具有更好的应用价值。

## 6 结束语

此次选择混合神经网络作为检测技术,分别在卷积神经网络和长短期记忆网络进行检测模型构建,实现对锅炉燃烧设备的智能检测,并通过实验论证了检测方法的有效性。但由于时间有限,在研究中仅能针对三组故障状态进行分析,具有不足之处。未来会进一步研究基于混合神经网络的故障检测方法,如在结构优化以及参数调整上提出新的理论,为工业生产和能源安全提供更加可靠的保障。

## 参考文献:

- [1] QIAN H, QIU Y X, LU C H, et al. Analytical solution of temperature in laminated beams subjected to general thermal boundary conditions[J]. Journal of Central South University, 2022, 29(2): 561-571.
- [2] PU Taofei, LIU Shuqiang, LI Xiaobo, et al. Normally-off AlGaIn/GaN heterojunction field-effect transistors with in-situ AlN gate insulator[J]. Chinese Physics B, 2022, 31(12): 127701-127701.
- [3] 朱志平, 杨燕, 王杰. 基于场景图感知的跨模态图像描述模型[J]. 计算机应用, 2024, 44(1): 58-64.
- [4] 朱雨男, 解方形, 张明亮, 等. 基于多层双向长短期记忆网络的水声索引调制滤波器组多载波系统索引检测方法[J]. 电子与信息学报, 2022(44): 1-7.
- [5] 刘阳, 粟航, 何倩, 等. 基于云-边协同变分自编码神经网络的设备故障检测方法[J]. 计算机工程与科学, 2023, 45(7): 1188-1196.
- [6] 张云飞, 张俊, 吴龙, 等. 基于深度卷积神经网络的变电一次设备故障检测方法[J]. 电气传动, 2022, 52(23): 67-72.
- [7] 曹歌瀚, 黄亚继, 徐文韬, 等. 基于机器学习的燃煤锅炉工况建模与燃烧优化[J]. 锅炉技术, 2023, 54(5): 41-47.
- [8] 孙德良, 王田, 周宇哲, 等. 基于神经网络的锅炉燃烧控制

系统建模设计[J]. 电子设计工程, 2023, 31(10): 20-24.

[9] 卢颖, 毛杰. 基于馈线自动化功能的配电网故障定位技术[J]. 自动化技术与应用, 2023, 42(5): 19-22.

[10] 赵新, 芦博, 王丹丹, 等. 基于组件式GIS的配电网故障自动化定位系统[J]. 自动化技术与应用, 2023, 42(12): 146-149.

[11] 董巧玲. 基于改进神经网络的抽油机故障智能诊断研究[J]. 西安石油大学学报(自然科学版), 2022, 37(6): 124-132.

[12] 唐寅, 闫城, 朱静, 等. 基于传热性能变化的余热锅炉故障诊断及应用[J]. 热能动力工程, 2022, 37(10): 156-161.

作者简介: 崔小军(1988—), 男, 本科, 工程师, 研究方向: 智能发电技术研究。