

# 基于人工神经网络的锅炉燃烧智能化系统

姚金坤<sup>1</sup>, 姚博<sup>2</sup>

(1. 昆明醋酸纤维有限公司, 云南 昆明 650224; 2. 复旦大学 计算机科学技术学院, 上海 200433)

**摘要:**提出一种基于人工神经网络的锅炉燃烧智能化系统,学习锅炉运行参数与煤汽比间复杂的非线性映射关系,基于学到的映射关系动态调节锅炉运行参数,有效提高锅炉热效率,降低司炉工的劳动强度。该系统安装在35 t锅炉上,进行为期6个月的实验,实验结果表明,系统能够提高锅炉热效率,提高吨煤产汽量5.42%,节煤5.58%(平均231.31 t/月),降低司炉工的劳动强度95%。

**关键词:**锅炉燃烧智能化;节能减排;神经网络;人工智能

中图分类号:TK32 文献标识码:B DOI:10.16146/j.cnki.rndlgc.2020.03.036

[引用本文格式]姚金坤,姚博.基于人工神经网络的锅炉燃烧智能化系统[J].热能动力工程,2020,35(3):249-255. YAO Jin-kun, YAO Bo. Intelligent boiler combustion system based on artificial neural network[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(3):249-255.

## Intelligent Boiler Combustion System based on Artificial Neural Network

YAO Jin-kun<sup>1</sup>, YAO Bo<sup>2</sup>

(1. Kunming Cellulose Fibers Company Limited, Kunming, China, Post Code: 650224;  
2. School of Computer Science and Technology, Fudan University, Shanghai, China, Post Code: 200433)

**Abstract:** An artificial neural network based intelligent boiler combustion system is proposed to enhance the thermal efficiency of boiler and reduce the labor intensity of boiler workers. The system firstly learns the complex nonlinear mapping between boiler operating parameters and coal-steam ratio, then dynamically adjusts boiler operating parameters according to the learned nonlinear mapping. The system was deployed on our company's 35-ton boilers for a six-month experiment. The experimental results show that the proposed system improves the thermal efficiency of boiler, increases the steam production per ton of coal by 5.42%, saves coal by 5.58% (231.31 tons per month on average) and reduces the labor intensity of boiler workers by 95.0%.

**Key words:** intelligent boiler combustion, energy saving and emission reduction, artificial neural network, artificial intelligence

## 引言

提高锅炉热效率,能够尽可能充分地利用煤炭资源,减少环境有害物(例如CO<sub>2</sub>、CO和SO<sub>2</sub>)的排放,是实现锅炉节能减排的核心<sup>[1-2]</sup>。提高锅炉热效率的关键是控制好风煤比,提高燃烧的有效性,减少不完全燃烧热损失和排烟热损失<sup>[3-4]</sup>。目前,锅

炉燃烧控制的主要方式是司炉工根据经验调节锅炉运行参数,来提高锅炉热效率。但是,单纯依靠人的经验调节运行参数,存在一些不足:(1)锅炉运行参数种类多(例如主蒸汽温度、主蒸汽压力、炉膛温度、给水温度、给水流量、给风温度、给风量、排烟温度、排烟量、烟气氧含量等)、变化快,人的运算能力有限;(2)锅炉运行参数需要实时动态调节,人的精力有限且调节有滞后性;(3)锅炉运行参数与热效

率间存在着复杂的非线性映射关系,且该映射关系会随着锅炉的运行不断变化,单纯依靠人的经验调节,提高锅炉热效率有限。

因此,提出一种基于人工神经网络(Artificial Neural Network)<sup>[5-8]</sup>的锅炉燃烧智能化系统,该系统学习锅炉运行参数与煤汽比(即煤耗量/主蒸汽流量)间复杂的非线性映射关系,基于学到的映射关系实时动态调节锅炉运行参数,来提高锅炉热效率。多层感知机(Multiple Layer Perceptron)<sup>[5]</sup>是一种全连接(Fully Connection)的人工神经网络,它的拟合能力很强,只要一个多层感知机包含足够多的隐层(Hidden Layer)和神经元,它就可以以任意精度逼近任意复杂度的连续函数<sup>[9]</sup>。因此,提出的以多层感知机为基础设计的拟合模型能够较好地逼近锅炉运行参数与煤汽比间复杂的非线性映射关系,进而可以通过实时动态调节锅炉运行参数,有效提高锅炉热效率。

同时,针对该映射关系会随着锅炉的运行不断变化的问题,在锅炉燃烧智能化系统中加入“注意力(Attention)”<sup>[10-11]</sup>网络,动态微调锅炉运行参数与煤汽比间的复杂映射关系。“注意力”网络是一类特殊的人工神经网络,它可以模仿人的“注意力”。锅炉在运行时,有时不完全燃烧热损失是主要热损失(给风不足,燃烧不充分)，“注意力”网络会动态调高相关运行参数(例如给风温度、给风量等)的权重;有时排烟热损失是主要热损失(给风过量,排烟量过大)，“注意力”网络则会动态调低一些相关运行参数(例如给风量、排烟量等)的权重,据此来微调锅炉运行参数与热效率间的复杂映射关系。

提出的锅炉燃烧智能化系统安装在某35 t锅炉上,进行为期6个月的对比实验,实验结果表明,与传统人工燃烧控制系统相比,提出的系统能够提高锅炉热效率,提高吨煤产汽量5.42%,节煤5.58%(平均231.31 t/月),降低司炉工的劳动强度95%。

## 1 人工神经网络

### 1.1 多层感知机

人工神经网络<sup>[5]</sup>是一类模拟人脑神经网络的计算模型。它模仿人的学习过程来“学习”模型,习得的“知识”存储在模型参数中<sup>[6]</sup>。人工神经网络

的“学习”完成后,可以模拟人脑对输入的信息做出识别和判断,即用输入的信息与模型参数做计算,根据计算的结果做出识别和判断<sup>[8]</sup>。人工神经网络的基本单元是神经元(Neuron)模型<sup>[12]</sup>,其中M-P神经元模型<sup>[5]</sup>被广泛应用。该模型的输入是网络上一层中N个神经元的输出信号 $\mathbf{x} = (x_1, x_2, \dots, x_N)$ 。M-P神经元用输入信号 $\mathbf{x}$ 与模型参数 $(\boldsymbol{\omega}, \theta)$ 做计算以产生输出信号 $\mathbf{y}$ :

$$\mathbf{y} = f(\boldsymbol{\omega}\mathbf{x}^T - \theta) \tag{1}$$

式中: $\boldsymbol{\omega} = (\omega_1, \omega_2, \dots, \omega_N)$ 是连接权重(Connection Weight); $\theta$ —阈值(Threshold); $f$ —激活函数(Activation Function);常用的激活函数有sigmoid函数、tanh函数等。

多层感知机<sup>[5]</sup>由多层M-P神经元以全连接的方式构成,它包含一个输入层、L个隐层和一个输出层。用 $\mathbf{x} = (x_1, x_2, \dots, x_I)$ 表示多层感知机的输入信号, $\mathbf{y} = (y_1, y_2, \dots, y_O)$ 表示多层感知机的输出信号。I即多层感知机输入层的神经元个数,O即多层感知机输出层的神经元个数。多层感知机用输入信号 $\mathbf{x}$ 与模型参数做计算以产生输出信号 $\mathbf{y}$ :

$$\begin{aligned} h_1 &= f(x\Omega_1 - \theta_1) \\ h_2 &= f(h_1\Omega_2 - \theta_2) \\ &\vdots \\ h_l &= f(h_{l-1}\Omega_l - \theta_l) \\ &\vdots \\ h_L &= f(h_{L-1}\Omega_L - \theta_L) \\ y &= f(h_L\Omega_{out} - \theta_{out}) \end{aligned} \tag{2}$$

式中: $h_l = (h_l^1, h_l^2, \dots, h_l^H)$ 是多层感知机第l个隐层的输出信号,也是第l+1个隐层的输入信号,H是多层感知机隐层的神经元个数; $(\Omega_1, \Omega_2, \dots, \Omega_L, \Omega_{out}, \theta_1, \theta_2, \dots, \theta_L, \theta_{out})$ 均为多层感知机的模型参数,其中, $\Omega_1 \in \mathbb{R}^{I \times H}, \Omega_2, \dots, \Omega_L \in \mathbb{R}^{H \times H}$ 和 $\Omega_{out} \in \mathbb{R}^{H \times O}$ 是连接权重, $\theta_1, \theta_2, \dots, \theta_L \in \mathbb{R}^H$ 和 $\theta_{out} \in \mathbb{R}^O$ 是阈值。

### 1.2 BP算法

误差逆传播(Error BackPropagation, BP)算法<sup>[6]</sup>是一种常用的学习算法,该算法模拟人的学习过程来训练人工神经网络。以多层感知机 $\mathbf{y} = \varphi_{(\boldsymbol{\omega}, \theta)}(\mathbf{x})$ 为例,介绍BP算法。给定训练集 $D_{train} = \{(x_t, y_t)\}_{t=1}^T$ ,其中, $x_t \in \mathbb{R}^I, y_t \in \mathbb{R}^O, T$ 即训练集

的样本个数。对某一样本  $(x_t, y_t), y_t$  表示真实值 (Ground Truth),  $\hat{y}_t = \varphi_{(\Omega, \theta)}(x_t)$  表示多层感知机的输出值。常用均方误差  $L_{MSE}$  (Mean Square Error) 描述多层感知机输出值与真实值间的误差:

$$L_{MSE} = \frac{1}{T} \sum_{i=1}^T (\hat{y}_i - y_i) (y_i - \hat{y}_i)^T \quad (3)$$

这里  $L_{MSE}$  也被称作多层感知机的损失函数 (Loss Function) 或目标函数 (Objective Function)。BP 算法的目标是,找到一组模型参数  $(\Omega_k, \theta_k)$  满足:

$$(\Omega_k, \theta_k) = \underset{(\Omega, \theta)}{\operatorname{argmin}} L_{MSE} \quad (4)$$

BP 算法基于梯度下降 (Gradient Descent) 法,以迭代的方式不断更新模型参数  $(\Omega, \theta)$  :

$$\begin{aligned} \Omega_k &\leftarrow \Omega_{k-1} - \eta_{\Omega} \left. \frac{\partial L_{MSE}}{\partial \Omega} \right|_{\Omega = \Omega_{k-1}}, \eta_{\Omega} > 0 \\ \theta_k &\leftarrow \theta_{k-1} - \eta_{\theta} \left. \frac{\partial L_{MSE}}{\partial \theta} \right|_{\theta = \theta_{k-1}}, \eta_{\theta} > 0 \end{aligned} \quad (5)$$

式中:  $(\eta_{\Omega}, \eta_{\theta})$  是学习率 (Learning Rate)。

由于  $L_{MSE}$  关于  $(\Omega, \theta)$  是凸优化函数,当  $\left. \frac{\partial L_{MSE}}{\partial \Omega} \right|_{\Omega = \Omega_k} = 0$  且  $\left. \frac{\partial L_{MSE}}{\partial \theta} \right|_{\theta = \theta_k} = 0$  时,迭代完成,  $L_{MSE}$  达到最小值,  $(\Omega_k, \theta_k)$  即满足式 (4) 的模型参数。此时多层感知机的训练完成,训练中多层感知机习得的“知识”存储在模型参数  $(\Omega_k, \theta_k)$  中。

## 2 数值计算模型

### 2.1 锅炉燃烧智能化

随着锅炉的运行,锅炉运行参数  $X$  (例如主蒸汽温度、炉膛温度、给水温度、给水流量、给风温度、给风量、排烟温度、排烟量、烟气氧含量等)与锅炉煤汽比  $y$  在不断变化。使用  $X = (x_1, \dots, x_i, \dots, x_T)^T = (x^1, \dots, x^n, \dots, x^N)$  表示一段时间内锅炉的运行参数,  $T$  是这段时间内采集运行参数的时刻数,  $N$  是锅炉运行参数的个数。  $x_t = (x_t^1, x_t^2, \dots, x_t^N)$  表示  $t$  时刻采集的锅炉运行参数,  $x^n = (x_1^n, x_2^n, \dots, x_T^n)^T$  表示这段时间内采集的第  $n$  个运行参数。使用  $y = (y_1, y_2, \dots, y_i, \dots, y_T)$  表示这段时间内锅炉煤汽比,  $y_i$  表示  $t-1$  时刻到  $t$  时刻锅炉的煤汽比。

锅炉运行参数  $X$  与煤汽比  $y$  间存在着复杂的非线性映射关系  $y = \Gamma(X)$ , 该映射关系会随着锅炉的运行不断变化:

$$y = \Gamma(X) \Leftrightarrow \begin{cases} y_1 = \varphi_1(x_1) \\ y_2 = \varphi_2(x_2) \\ \vdots \\ y_i = \varphi_i(x_i) \\ \vdots \\ y_T = \varphi_T(x_T) \end{cases} \quad (6)$$

锅炉燃烧智能化即建立一个有效的拟合模型  $y = \Phi(X)$ , 来描述锅炉运行参数  $X$  与煤汽比  $y$  间复杂的非线性映射关系  $\Gamma(\cdot) = [\varphi_1(\cdot), \dots, \varphi_T(\cdot)]$ ; 基于模型  $\Phi(\cdot)$  动态调节锅炉运行参数, 尽可能地提高锅炉的热效率。

### 2.2 锅炉燃烧智能化系统

基于神经网络<sup>[5-8]</sup>的锅炉燃烧智能化系统结构如图1所示。该系统包含运行模块、拟合模块和控制模块。运行模块由锅炉和传感器组成,传感器实时监测锅炉的运行参数  $X$  和煤汽比  $y$ 。

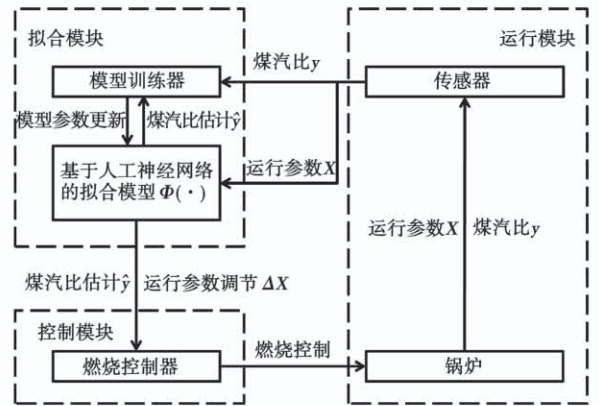


图1 锅炉燃烧智能化系统结构图

Fig.1 The architecture of the proposed intelligent boiler combustion system

拟合模块由基于神经网络的拟合模型  $\Phi(\cdot)$  和模型训练器组成,用于拟合锅炉运行参数  $X$  与煤汽比  $y$  间复杂的非线性映射关系  $y = \Gamma(X)$ 。模型训练器不断收集传感器监测到的煤汽比  $y$  和拟合模型  $\Phi(\cdot)$  估计的煤汽比  $\hat{y}$ , 但只有两种情况下,模型训练器才会被激活去更新拟合模型  $\Phi(\cdot)$  的模型参数。第一种情况是系统启动时,第二种情况是系统运行时,模型训练器监测到模型  $\Phi(\cdot)$  估计的煤汽比  $\hat{y}$  与真实的煤汽比  $y$  间的误差大于某个预先设定的阈值。

控制模块由燃烧控制器组成。燃烧控制器接收

拟合模型  $\Phi(\cdot)$  给出的锅炉运行参数调节“建议”  $\Delta X$ , 并根据该“建议”动态调节锅炉运行参数  $X$ , 实现智能的燃烧控制。燃烧控制器与模型训练器是“互斥”的, 即模型训练器被激活时, 燃烧控制器不工作; 模型训练器不工作时, 燃烧控制器工作。这一机制保证了在燃烧控制时, 拟合模型  $\Phi(\cdot)$  是有效的, 根据  $\Phi(\cdot)$  的“建议”做出的燃烧控制是有效的。

### 2.3 基于人工神经网络的拟合模型

#### 2.3.1 拟合模型

锅炉运行参数  $X$  与煤汽比  $y$  间存在着复杂的非线性映射关系  $y = \Gamma(X)$ , 且该映射关系会随着锅炉的运行不断变化(如式(6)所示)。如何建立一个有效的模型  $y = \Phi(X)$ , 来描述  $y = \Gamma(X)$  是锅炉燃烧智能化的难点。

提出一种“注意力”网络  $f(\cdot)$  与估计网络  $g(\cdot)$  相结合的拟合模型  $\Phi(\cdot)$ , 来描述锅炉运行参数  $X$  与煤汽比  $y$  间复杂的非线性映射关系  $\Gamma(\cdot)$ 。一个多层感知机只要包含足够多的隐层和神经元, 它可以以任意精度逼近任意复杂度的连续函数<sup>[11]</sup>。因此, 以多层感知机为基础的“注意力”网络  $f(\cdot)$  和估计网络  $g(\cdot)$  拟合能力较强, 能够去拟合复杂的非线性映射关系  $\Gamma(\cdot)$ 。此外, 针对  $\Gamma(\cdot)$  会随着锅炉的运行不断变化的问题, 提出一种“注意力”网络  $f(\cdot)$  与估计网络  $g(\cdot)$  巧妙结合的方式:

$$y = \Phi(X) \Leftrightarrow \begin{cases} y_1 = g(x_1 \otimes f(x_1)) \\ y_2 = g(x_2 \otimes f(x_2)) \\ \dots \\ y_t = g(x_t \otimes f(x_t)) \\ \dots \\ y_T = g(x_T \otimes f(x_T)) \end{cases} \quad (7)$$

式中:  $y = (y_1, y_2, \dots, y_t, \dots, y_T)$  — 锅炉的煤汽比;  $X = (x_1, \dots, x_t, \dots, x_T)^T$  — 锅炉的运行参数;  $\otimes$  表示两个向量的逐点相乘。

这样, 实现了用两个固定的映射的组合, 即  $[y_t = g(x_t \otimes f(x_t))]_{t=1}^T$ , 来描述不断变化的映射  $\Gamma(\cdot) = [\varphi_1(\cdot), \dots, \varphi_t(\cdot), \dots, \varphi_T(\cdot)]$ 。映射  $\Gamma(\cdot)$  是不断变化的, 针对每个映射  $\varphi_t(\cdot)$ , 只有一个样本点  $(x_t, y_t)$ , 几乎不可能拟合出  $\varphi_t(\cdot)$ , 而映射  $\Phi(\cdot)$  是固定的, 可以使用整个样本集  $(X, y) = \{(x_t, y_t)\}_{t=1}^T$  来拟合。

“注意力”网络  $f(\cdot)$  的输入是  $t$  时刻采集的锅炉运行参数  $x_t \in \mathbb{R}^N$  ( $N$  是锅炉运行参数的个数), 输出  $f(x_t) \in \mathbb{R}^N$  是各个运行参数在  $t$  时刻的“注意力”权重。某个运行参数的“注意力”权重较大, 表示在当前锅炉运行状态下, 该参数对锅炉煤汽比的影响较大, 估计网络  $g(\cdot)$  会更多地“注意”它。“注意力”网络  $f(\cdot)$  以多层感知机为基础, 根据锅炉运行状态  $x_t$  计算各个运行参数的“注意力”权重  $f(x_t)$ :

$$\begin{aligned} h_1^f &= \text{sigmoid}(x_t \Omega_1^f - \theta_1^f) \\ h_2^f &= \text{sigmoid}(h_1^f \Omega_2^f - \theta_2^f) \\ &\vdots \\ h_l^f &= \text{sigmoid}(h_{l-1}^f \Omega_l^f - \theta_l^f) \\ &\vdots \\ h_L^f &= h_{L-1}^f \Omega_L^f - \theta_L^f \\ f(x_t) &= \text{softmax}(h_L^f) \end{aligned} \quad (8)$$

式中:  $h_l^f$  — 第  $l$  个隐层的输出信号, 也是第  $l + 1$  个隐层的输入信号;  $L$  — 网络  $f(\cdot)$  隐层的个数;  $(\Omega_1^f, \dots, \Omega_L^f, \theta_1^f, \dots, \theta_L^f)$  — “注意力”网络  $f(\cdot)$  的模型参数;  $(\Omega_1^f, \dots, \Omega_L^f)$  — 连接权重;  $(\theta_1^f, \dots, \theta_L^f)$  — 阈值。sigmoid 函数是向量函数:

$$\begin{aligned} a &= (a_1, a_2, \dots, a_p, \dots, a_p) \\ \text{sigmoid}(a) &= \left( \frac{1}{1 + e^{-a_p}} \right)_{p=1}^p \end{aligned} \quad (9)$$

softmax 函数也是向量函数:

$$\begin{aligned} b &= (b_1, b_2, \dots, b_q, \dots, b_q) \\ \text{softmax}(b) &= \left( \frac{e^{b_q}}{\sum_{j=1}^q e^{b_j}} \right)_{q=1}^q \end{aligned} \quad (10)$$

估计网络  $g(\cdot)$  根据  $t$  时刻加权的锅炉运行参数  $z_t = x_t \otimes f(x_t) \in \mathbb{R}^N$ , 估计  $t$  时刻锅炉的煤汽比  $\hat{y}_t = g(z_t) \in \mathbb{R}$ :

$$\begin{aligned} h_1^g &= \text{sigmoid}(z_t \Omega_1^g - \theta_1^g) \\ h_2^g &= \text{sigmoid}(h_1^g \Omega_2^g - \theta_2^g) \\ &\vdots \\ h_r^g &= \text{sigmoid}(h_{r-1}^g \Omega_r^g - \theta_r^g) \\ &\vdots \\ h_R^g &= \text{sigmoid}(h_{R-1}^g \Omega_R^g - \theta_R^g) \\ \hat{y}_t &= h_R^g (\omega_{\text{out}}^g)^T - \theta_{\text{out}}^g \end{aligned} \quad (11)$$

式中:  $h_r^g$  — 第  $r$  个隐层的输出信号, 也是第  $r + 1$  个隐层的输入信号;  $R$  — 网络  $g(\cdot)$  隐层的个数;

$(\Omega_1^g, \dots, \Omega_R^g, \omega_{out}^g, \theta_1^g, \dots, \theta_R^g, \theta_{out}^g)$ —估计网络  $g(\cdot)$  的模型参数。

### 2.3.2 拟合模型的训练

给定训练集  $(X, y) = \{(x_t, y_t)\}_{t=1}^T$ , 对  $t$  时刻样本  $(x_t, y_t)$ ,  $y_t$  表示监测到的锅炉煤汽比,  $\hat{y}_t = g(x_t \otimes f(x_t))$  表示拟合模型  $\Phi(\cdot)$  估计的锅炉煤汽比。 $L_{RMSE}$  是用于训练拟合模型  $\Phi(\cdot)$  的损失函数:

$$L_{RMSE} = \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2} \quad (12)$$

训练采用 BP 算法,以迭代的方式不断更新模型参数  $(\Omega, \theta)$  :

$$\begin{aligned} \Omega_k &\leftarrow \Omega_{k-1} - \eta_\Omega \left. \frac{\partial L_{RMSE}}{\partial \Omega} \right|_{\Omega=\Omega_{k-1}}, \eta_\Omega > 0 \\ \theta_k &\leftarrow \theta_{k-1} - \eta_\theta \left. \frac{\partial L_{RMSE}}{\partial \theta} \right|_{\theta=\theta_{k-1}}, \eta_\theta > 0 \end{aligned} \quad (13)$$

式中:  $(\eta_\Omega, \eta_\theta)$ —学习率。

当  $\left. \frac{\partial L_{RMSE}}{\partial \Omega} \right|_{\Omega=\Omega_k} = 0$  且  $\left. \frac{\partial L_{RMSE}}{\partial \theta} \right|_{\theta=\theta_k} = 0$  时,迭代完成(即训练完成),  $(\Omega_k, \theta_k)$  为最终模型参数。

### 2.3.3 调节锅炉运行参数

基于完成训练的拟合模型  $\Phi(\cdot)$ , 可以实时给出锅炉运行参数调节“建议”  $\Delta x$ 。若当前为  $t$  时刻,对  $t+1$  时刻给出的调节“建议”  $\Delta x_m$  满足:

$$\Delta x_m = \underset{\Delta x}{\operatorname{argmin}} ( (x_t \oplus \Delta x) \otimes f(x_t \oplus \Delta x) ) \quad (14)$$

式中:  $f(\cdot)$ —“注意力”网络;  $g(\cdot)$ —估计网络;  $\oplus$ —两个向量的逐点相加;  $\otimes$ —两个向量的逐点相乘。

通过梯度下降法,以迭代的方式计算得到  $\Delta x_m$  :

$$\Delta x_m \leftarrow \Delta x_{m-1} - \eta_{\Delta x} \left. \frac{\partial \varphi(\Delta x)}{\partial \Delta x} \right|_{\Delta x=\Delta x_{m-1}} \quad (15)$$

$$\varphi(\Delta x) = g((x_t \oplus \Delta x) \otimes f(x_t \oplus \Delta x))$$

式中:  $\eta_{\Delta x} > 0$  是步长。

当  $\left. \frac{\partial \varphi(\Delta x)}{\partial \Delta x} \right|_{\Delta x=\Delta x_m} = 0$  时,迭代完成,  $\Delta x_m$  即满足式(14)的调节“建议”。

## 3 实验结果与讨论

### 3.1 实验数据和实验设计

基于人工神经网络的锅炉燃烧智能化系统安装在某 35 t 锅炉上,进行了为期 6 个月的实验。实验

数据包括锅炉运行参数  $X$  和锅炉煤汽比  $y$ 。锅炉运行参数  $X$  有 10 个,包括主蒸汽温度、主蒸汽压力、炉膛温度、给水温度、给水流量、给风温度、给风量、排烟温度、排烟量和烟气氧含量。锅炉上的传感器每隔 1 小时采集 1 次数据,6 个月的实验期内,共采集 4320 条数据(1 条数据为 1 组  $(x_t, y_t)$ )。

前 3 个月进行模型拟合实验,锅炉燃烧智能化系统的模型训练器工作,燃烧控制器不工作。实验除使用提出的拟合模型  $y = \Phi(X)$  外,还使用了另外 4 个拟合模型作为对比,包括线性回归(Linear Regression)模型、二次回归(Quadratic Regression)模型、多层感知机(Multiple Layer Perceptron)<sup>[5]</sup>模型和自编码(Autoencoder)<sup>[13]</sup>模型。其中,多层感知机模型和自编码模型均为人工神经网络。实验采用十折交叉验证的方式,模型拟合的效果用 RMSE(Root Mean Square Error)、MAE(Mean Absolute Error)和 MAPE(Mean Absolute Percentage Error)来评估。给定测试集  $D_{\text{test}} = \{(x_s, y_s)\}_{s=1}^S$ ,  $S$  即测试集的样本个数。 $y_s$  表示传感器监测到的锅炉煤汽比,  $\hat{y}_s$  表示拟合模型估计的锅炉煤汽比。对  $s$  时刻样本  $(x_s, y_s)$ , RMSE、MAE 和 MAPE 分别计算如下:

$$\begin{aligned} E_{\text{RMSE}} &= \sqrt{\frac{1}{S} \sum_{s=1}^S (\hat{y}_s - y_s)^2} \\ E_{\text{MAE}} &= \frac{1}{S} \sum_{s=1}^S |\hat{y}_s - y_s| \\ E_{\text{MAPE}} &= \frac{100\%}{S} \sum_{s=1}^S \left| \frac{\hat{y}_s - y_s}{y_s} \right| \end{aligned} \quad (16)$$

后 3 个月进行锅炉燃烧智能化实验,基于前 3 个月训练好的拟合模型  $\Phi(\cdot)$ , 动态调节锅炉运行参数,记录锅炉煤汽比的变化。在实验中,一般情况下,锅炉燃烧智能化系统的模型训练器不工作,燃烧控制器工作;当监测到拟合模型  $\Phi(\cdot)$  估计的煤汽比  $\hat{y}_t$  与真实的煤汽比  $y_t$  间的误差大于某个预先设定的阈值时,模型训练器暂时工作,燃烧控制器暂时不工作。

## 3.2 实验结果与分析

### 3.2.1 模型拟合

前 3 个月进行模型拟合实验,除使用提出的拟合模型  $y = \Phi(X)$  外,还使用了另外 4 个拟合模型作为对比,实验结果如表 1 所示。

表 1 模型拟合结果

Tab. 1 The experimental results of model fitting

拟合模型	评估指标		
	RMSE	MAE	MAPE
线性回归	0.226 ± 0.021	0.221 ± 0.019	171.2% ± 10.5%
二次回归	0.133 ± 0.015	0.140 ± 0.017	109.6% ± 6.4%
多层感知机	0.038 ± 0.006	0.036 ± 0.007	28.9% ± 1.9%
自编码	0.032 ± 0.007	0.035 ± 0.005	24.4% ± 2.1%
提出的模型	0.023 ± 0.005	0.024 ± 0.006	16.3% ± 1.9%

锅炉运行参数  $X$  与煤汽比  $y$  间存在着复杂的非线性映射关系  $y = f(X)$ , 线性回归模型的拟合效果很差 (MAPE 高达 171.2%)。二次回归模型 (非线性模型) 的拟合效果相比于线性回归模型, 有显著的提升 (MAPE 下降 61.6%)。但二次回归模型的拟合能力仍有限, 不能较好地描述  $f(\cdot)$  (MAPE 仍高达 109.6%)。

多层感知机模型、自编码模型和提出的模型  $\Phi(\cdot)$  均为人工神经网络, 具有较强的拟合能力, 拟合效果较好 (MAPE 均低于 30%)。提出的模型  $\Phi(\cdot)$  通过巧妙组合“注意力”网络与估计网络, 能够描述随着锅炉的运行不断变化的映射  $f(\cdot)$ 。相比于只能描述固定映射的多层感知机模型和自编码模型,  $\Phi(\cdot)$  的拟合效果更好 (MAPE 较多层感知机模型下降 12.6%, 较自编码模型下降 8.1%)。

### 3.2.2 锅炉燃烧智能化

后 3 个月进行锅炉燃烧智能化实验, 实验结果如表 2 所示。

表 2 锅炉燃烧智能化实验结果

Tab. 2 The experimental results of intelligent boiler combustion

控制 系统	月份	煤耗 量/t	主蒸汽 流量/t	吨煤产 汽量/t	劳动强 度/次
人工燃 烧控制	3 月	4120.35	25185.91	6.1126	18566
	4 月	4086.90	24959.94	6.1073	18032
	5 月	4235.25	26297.43	6.2092	18231
智能系 统燃烧 控制	6 月	3939.00	25476.29	6.4677	905
	7 月	3793.63	24594.01	6.4830	877
	8 月	4015.94	26015.99	6.4782	960

表 2 中, 每月统计 30 天 (1 ~ 30 日) 的数据, 统计的数据是同一锅炉在同一工况下的运行数据。吨煤产汽量用主蒸汽流量除以煤耗量计算, 劳动强度用司炉工对锅炉的操作次数表示。提出的锅炉燃烧智能化系统, 基于拟合模型  $\Phi(\cdot)$ , 自动调节锅炉运行参数, 有效提高了锅炉热效率, 提高了吨煤产汽量 5.58%, 平均每月节煤 231.31 t, 降低司炉工的劳动强度 95.0%。锅炉燃烧智能化系统取得成效的关键在于, 建立模型去“学习”锅炉运行参数与煤汽比间复杂的非线性映射关系, 并根据“学到”的映射关系做出“智能的”燃烧控制。

此外, 如图 2 所示, 人工的燃烧控制存在滞后性且调节幅度容易过大, 供汽的稳定性较差。智能系统的燃烧控制是实时的且以微调为主, 供汽的稳定性较好, 更有利于生产安全。




图 2 锅炉主蒸汽温度变化图

Fig. 2 Temperature variation of main steam

## 4 结 论

在锅炉上部署提出的基于人工智能的燃烧控制系统, 实现了锅炉燃烧的智能化控制。与传统人工燃烧控制系统相比, 提出的智能系统能够有效提高锅炉热效率, 提高吨煤产汽量 5.42%, 节煤 5.58% (平均 231.31 t/月), 降低司炉工的劳动强度 95%。此外, 智能系统的安装提高了锅炉供汽的稳定性, 减少了烟气中废气 (如  $CO_2$ 、 $SO_2$  等) 的排放浓度和排放总量。在 35 t 锅炉上安装该智能系统后, 节约的煤炭成本, 10 个月便超过了安装系统的费用。

基于人工神经网络的锅炉燃烧智能化系统是人工智能技术在工业界的一次成功尝试, 今后会继续深入研究基于人工智能的锅炉节能减排技术。

## 参考文献:

- [1] BARIDO D P L, SUFFIAN S, KAMMEN D M, et al. Opportunities for behavioral energy efficiency and flexible demand in data limited low-carbon resource constrained environments [J]. *Applied Energy*, 2018, 228: 512 – 523.
- [2] ERVURAL B C, ZAIM S, DELEN D. A two-stage analytical approach to assess sustainable energy efficiency [J]. *Energy*, 2018, 164: 822 – 836.
- [3] CHUAHY F D F, KOKJOHN S L. High Efficiency Dual-Fuel Combustion Through Thermochemical Recovery and Diesel Reforming [J]. *Applied Energy*, 2017(195): 503 – 522.
- [4] SCHMITZ M, LINDERHOLM C, HALLBERG P, et al. Chemical-looping combustion of solid fuels using manganese ores as oxygen carriers [J]. *Energy Fuels*, 2016(30): 1204 – 1216.
- [5] MCCULLOCH W S, PITTS W H. A logical calculus of ideas immanent in nervous activity [J]. *The Bulletin of Mathematical Biophysics*, 1942(5): 115 – 133.
- [6] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. *Nature*, 1986(323): 533 – 536.
- [7] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006(313): 504 – 507.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]. *Advances in Neural Information Processing Systems*, 2012.
- [9] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, 2(5): 359 – 366.
- [10] BA J L, MNH V, KAVUKCUOGLU K. Multiple object recognition with visual attention [C]. *The International Conference on Learning Representations*, 2015.
- [11] MNH V, HEES N, GRAVES A, et al. Recurrent models of visual attention [C]. *Advances in Neural Information Processing Systems*, 2014.
- [12] HASTIE T, TIBSHIRANI R, FRIEDMAN J. *The elements of statistical learning* [M]. Springer, 2015: 389 – 415.
- [13] KINGMA D P, WELING M. Auto-encoding variational bayes [C]. *International Conference on Learning Representations*, 2013.

(姜雪梅 编辑)