

文章编号:1001-2060(2024)03-0073-09

# 基于线性回归与BP神经网络的火电厂 燃煤碳排放计算研究

龚广京<sup>1</sup>,周光<sup>1</sup>,郑涛<sup>1</sup>,陈时熠<sup>2</sup>

(1. 国电南瑞科技股份有限公司,江苏南京 211006; 2. 东南大学 能源与环境学院,江苏南京 210096)

**摘要:**针对燃煤电厂普遍缺少煤炭元素分析数据的现状,以我国商品煤煤质数据库中的3 000余条煤质数据为基础,分别采用线性回归、BP神经网络、SSA-BP神经网络模型对煤炭工业分析数据进行建模,预测煤炭元素分析含碳量,进而从原料侧计算燃煤碳排放,3种模型对于煤炭元素分析含碳量预测的相对误差分别为8.40%,2.51%,1.30%。选取某百万机组燃煤电厂平稳负荷、波动负荷、升负荷、降负荷4种典型工况,从原料侧通过上述3种模型开展电厂燃煤连续碳排放计算,并与电厂烟气侧检测碳排放值进行比较。结果表明:线性回归、BP神经网络、SSA-BP神经网络模型可以较好地推测元素分析含碳量。3种模型在平稳负荷的低负荷、中负荷、高负荷3种工况下,与锅炉烟气侧测量所得燃煤碳排放的均方根误差RMSE分别为0.35,0.08,0.07;0.87,0.37,0.09;0.23,0.19,0.17。在升负荷、降负荷、波动负荷工况下,3种模型计算值的均方根误差RMSE分别为1.00,0.84,0.71;1.43,1.24,0.73;1.33,1.15,0.93。以某电厂典型工作日为例,3种模型对日总碳排放计算值与烟气检测法获得的碳排放相对偏差分别为12.28%,5.52%,0.22%。SSA-BP神经网络模型煤质预测和碳排放计算结果与烟气侧测量值偏差最小。

**关键词:**碳排放;工业分析;元素分析;线性回归;神经网络

中图分类号:TQ533 文献标识码:A DOI:10.16146/j.cnki.rndlge.2024.03.010

[引用本文格式] 龚广京,周光,郑涛,等. 基于线性回归与BP神经网络的火电厂燃煤碳排放计算研究[J]. 热能动力工程, 2024, 39(3): 73-81. GONG Guang-jing, ZHOU Guang, ZHENG Tao, et al. Study on coal-fired carbon emission in thermal power plants based on linear regression and BP neural network[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(3): 73-81.

## Study on Coal-fired Carbon Emission in Thermal Power Plants based on Linear Regression and BP Neural Network

GONG Guang-jing<sup>1</sup>, ZHOU Guang<sup>1</sup>, ZHENG Tao<sup>1</sup>, CHEN Shi-yi<sup>2</sup>

(1. NARI Technology Co., Ltd., Nanjing, China, Post Code: 211006;

2. School of Energy and Environment, Southeast University, Nanjing, China, Post Code: 210096)

**Abstract:** In view of the general lack of coal ultimate analysis data in coal-fired power plants, based on more than 3 000 pieces of quality data in China's commercial coal quality database, a linear regression model, a BP neural network model and a sparrow search algorithm (SSA) optimized BP neural network model were established. The coal proximate analysis data were fitted in three models to predict the carbon content of the coal ultimate analysis, which was further applied to calculate the carbon emission of coal combustion from stock side, and the relative errors of the carbon content of the coal ultimate analysis predicted by three models were 8.40%, 2.51% and 1.30%, respectively. A 1 000 MW power plant unit under four typical load conditions of stationary load, fluctuating load, load up and load down was selected to

收稿日期:2023-06-02; 修订日期:2023-07-11

基金项目:国电南瑞南京控制系统有限公司科技项目(524609220030)

Fund-supported Project: Scientific Project of NARI Technology Nanjing Control System Co., Ltd. (524609220030)

作者简介:龚广京(1988-),男,国电南瑞科技股份有限公司工程师。

通信作者:郑涛(1977-),男,国电南瑞科技股份有限公司高级工程师。

calculate the continuous coal-fired carbon emissions through the proposed three models from stock side, and the carbon emission value was compared with that detected from flue gas side of power plant. The results show that the proposed linear regression, BP neural network and SSA-BP neural network models can predict the carbon content of coal ultimate analysis well. The root mean square error (RMSE) of carbon emissions of coal combustion obtained from flue gas side under three working conditions of low, medium and high stationary loads are 0.35, 0.08, 0.07 and 0.87, 0.37, 0.09 as well as 0.23, 0.19, 0.17. The RMSEs of computational values of three models under three working conditions of load up, load down and load fluctuation are 1.00, 0.84, 0.71 and 1.43, 1.24, 0.73 as well as 1.33, 1.15, 0.93. Taking a typical working day of a power plant as an example, the relative deviations between the total daily carbon emissions calculated by three models and the carbon emissions obtained by flue gas detection method are 12.28%, 5.52% and 0.22%, respectively. SSA-BP neural network model has the smallest deviation of the coal quality prediction and carbon emission calculation result from the measured values on the flue gas side.

**Key words:** carbon emission, proximate analysis, ultimate analysis, linear regression, neural network

## 引言

碳排放计量是“碳达峰、碳中和”的重要技术支撑<sup>[1-3]</sup>。燃煤发电企业已成为全国首批纳入碳市场的交易对象<sup>[4]</sup>。用煤收到基碳元素含量来计算碳排放量是目前发电企业碳排放核算的法定方法。但是煤元素分析实验过程复杂且耗时长。我国大部分电厂只开展煤的工业分析,未开展元素分析项目。研究如何将工业分析数据转化为元素分析碳元素含量,并准确计算碳排放量,具有重要的实际应用价值。

目前,已有研究将工业分析与元素分析进行线性回归建模<sup>[5-7]</sup>,该方法模型简单,但煤元素分析与工业分析数据之间并非简单线性映射,回归模型误差较大。误差反向传播(Back Propagation, BP)神经网络可以根据输入输出数据逼近任意非线性映射,为提高工业分析数据转化为元素分析数据精度提供了有力工具<sup>[8]</sup>。此外,根据当前核算指南,碳市场中火电燃煤碳排放是基于排放因子法的原料侧核算方法,存在统计时间跨度长、测量误差大、易造假等弊端。未来烟气侧碳排放计量也可能成为法定核算方式<sup>[9]</sup>。烟气侧和原料侧碳排放计量核算的差异及辨析目前研究较少。

本文采用线性回归、BP 神经网络、麻雀搜索优化 BP(SSA-BP)神经网络算法开展煤炭元素分析碳元素量计算,进而核算火电厂燃煤碳排放,并与火电厂实际燃烧后烟气侧碳排放监测数据对比,比较原料侧和烟气侧核算的关联性和原料侧模型的准确性,为火电厂燃煤原料侧碳排放核算建立一种新方法。

## 1 煤质数据收集与预处理

### 1.1 煤的工业分析与元素分析

采集了中国煤炭资源数据库中的3 000余条煤质数据,涵盖了无烟煤、贫煤、烟煤和褐煤等煤种的煤质数据。该数据库元素分析以空气干燥基为基准,包括空气干燥基碳元素含量  $C_{ad}$ 、空气干燥基氢元素含量  $H_{ad}$ 、空气干燥基氮元素含量  $N_{ad}$  和空气干燥基氧元素含量  $O_{ad}$ 。工业分析数据包括空气干燥基水分  $M_{ad}$ 、干燥基灰分  $A_{ad}$ 、干燥无灰基挥发分  $V_{ad}$ 、固定碳  $FC_{ad}$ 、硫分  $S_{td}$ 、空气干燥基高位发热量  $Q_{gr,ad}$  和收到基低位发热量  $Q_{net,ar}$ 。

为统一工业分析数据与元素分析数据基准,将不同基准下工业分析数据转化为空气干燥基数据,即:

$$M_{ad} + A_{ad} + V_{ad} + FC_{ad} = 100\% \quad (1)$$

以空气干燥基为基准,计算所采集的煤质工业分析数据的分布范围如表1所示。

表1 煤质工业分析和元素分析数据分布范围

Tab. 1 Coals' proximate and ultimate analysis data

工业分析/%				$Q_{gr,ad}/$		元素分析/%			
$M_{ad}$	$A_{ad}$	$V_{ad}$	$FC_{ad}$	$MJ \cdot kg^{-1}$		$C_{ad}$	$H_{ad}$	$N_{ad}$	$O_{ad}$
0.12~27.36	3.70~78.33	2.68~40.91	6.77~88.40	8.60~34.39	10.28~95.00	0.38~6.09	0.01~11.56	0.02~44.21	

由于不同煤种煤质数据差异过大,若采用统一模型进行计算易导致误差过大。为提高计算精度,按照煤炭挥发分含量对煤种进行分类,对不同煤种分别建模。

根据煤炭分类标准<sup>[10]</sup>,按煤炭挥发分含量  $V_{\text{daf}}$  的多少将煤炭分类为无烟煤、贫煤、烟煤和褐煤。煤炭挥发分含量小于 0.1 为无烟煤,煤炭挥发分含量 0.1~0.2 为贫煤,煤炭挥发分含量 0.2~0.4 为烟煤,煤炭挥发分含量大于 0.4 为褐煤。

## 1.2 燃煤碳排放计算方法

燃煤电厂总二氧化碳排放  $E$  为:

$$E = E_{\text{coal}} + E_{\text{se}} \quad (2)$$

式中: $E_{\text{coal}}$ —煤炭燃烧碳排放,t; $E_{\text{se}}$ —湿法脱硫消耗石灰石引起的二氧化碳排放量,t。

通过元素分析含碳量计算燃煤火电厂煤炭燃烧碳排放计算公式为:

$$E_{\text{coal}} = W_{\text{coal}} \times \left( C_{\text{ar}} - A_{\text{ar}} \times \frac{\bar{C}}{1 - \bar{C}} \right) \times \frac{44}{12} \quad (3)$$

式中: $W_{\text{coal}}$ —消耗的原煤量,t; $C_{\text{ar}}$ —煤炭收到基加权平均含碳量,%; $A_{\text{ar}}$ —煤炭收到基灰分,%; $\bar{C}$ —灰渣平均含碳量,即灰渣中平均含碳量占燃煤灰量的百分比,%;44—二氧化碳的摩尔质量;12—碳元素的摩尔质量。

通过燃煤电厂碳酸钙消耗量计算脱硫工艺碳排放的具体计算公式为:

$$E_{\text{se}} = W_{\text{CaCO}_3} \times \frac{44}{100} \quad (4)$$

式中: $E_{\text{se}}$ —湿法脱硫消耗石灰石引起的二氧化碳排放量,t; $W_{\text{CaCO}_3}$ —碳酸钙消耗量,t;100—碳酸钙的分子量,无量纲。

## 2 线性回归模型

### 2.1 线性回归算法

线性回归算法是处理多个变量之间数据关系的数理统计方法,即根据统计数据建立因变量( $Y$ )与  $k$  个自变量( $x_1, x_2, x_3, \dots, x_k$ )之间线性相关的近似数学表达式<sup>[11]</sup>。

### 2.2 线性回归模型结果

根据线性回归算法,设煤炭收到基碳元素含量为因变量,空气干燥基挥发分、空气干燥基固定碳、空气干燥基低位发热量、空气干燥基灰分为自变量,

假定空气干燥基的含碳量回归方程如下:

$$C_{\text{ad}} = \beta_0 + \beta_1 \times V_{\text{ad}} + \beta_2 \times FC_{\text{ad}} + \beta_3 \times Q_{\text{net,ar}} - \beta_4 \times A_{\text{ad}} \quad (5)$$

式中: $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4$ —回归系数;将煤质数据按照不同煤种代入,可得到不同煤种空气干燥基碳元素含量回归方程,如表 2 所示。

表 2 不同煤种空干基碳元素含量线性回归方程

Tab. 2 Linear regression equation of air dry base carbon element content in different coal types

煤种	空气干燥基碳元素含量回归方程
无烟煤	$C_{\text{ad}} = -7.77 + 0.60 \times V_{\text{ad}} + 1.05 \times FC_{\text{ad}}$
贫煤	$C_{\text{ad}} = 27.10 + 0.27 \times V_{\text{ad}} - 0.23 \times FC_{\text{ad}} + 2.47 \times Q_{\text{net,ad}}$ $- 0.27 \times A_{\text{ar}}$
烟煤	$C_{\text{ad}} = 10.25 + 0.10 \times V_{\text{ad}} + 0.25 \times FC_{\text{ad}} + 1.63 \times Q_{\text{net,ad}}$ $- 0.13 \times A_{\text{ar}}$
褐煤	$C_{\text{ad}} = 3.23 + 0.21 \times V_{\text{ad}} + 0.50 \times FC_{\text{ad}} + 1.19 \times Q_{\text{net,ad}}$ $- 0.06 \times A_{\text{ar}}$

## 3 BP 神经网络模型

### 3.1 BP 神经网络结构

BP 神经网络由输入层、隐藏层和输出层 3 部分组成<sup>[12]</sup>。其中,输入层接收外部数据,输出层输出预测结果,而隐藏层则起到了对输入数据进行特征提取和转换的作用。BP 神经网络结构如图 1 所示。

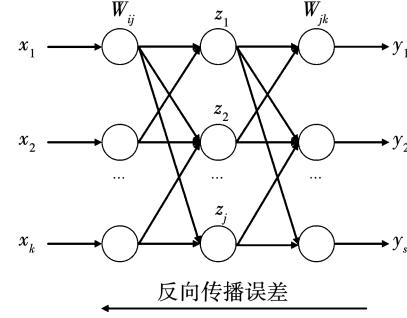


图 1 BP 神经网络结构图

Fig. 1 Structure diagram of BP neural network

BP 神经网络的输出预测结果如下:

$$y_n = \sum_{n=1}^s f(\sum_{i=1}^l w_{ij}x_i - b_j) n_{jk} - a_c \quad (6)$$

式中: $y_n$ —网络的输出结果; $f$ —激活函数; $w_{ij}$ —第  $i$  个神经元到第  $j$  个神经元的连接权重; $x_i$ —输入层第  $i$  个神经元的输出结果; $b_j$ —第  $j$  个神经元的偏置;

$n_{jk}$ —隐含层第  $j$  个神经元与输出层第  $k$  个神经元的连接权值;  $a_c$ —输出层第  $c$  个神经元的阈值;  $l$ —隐藏层神经元个数;  $s$ —输出层神经元个数。

### 3.2 BP 神经网络的训练过程

BP 神经网络的训练过程分为前向传播和反向传播两个阶段。在前向传播阶段, 输入数据通过输入层传递到隐藏层, 并在隐藏层中进行加权和激活函数的计算。隐藏层的输出被传递到输出层进行加权和激活函数的计算, 最终得到网络输出结果。在反向传播阶段, 首先计算网络输出结果与真实标签之间的误差, 并将误差反向传播到网络中, 更新输出层和隐藏层之间的权重和偏置。将误差从隐藏层反向传播到输入层, 同样根据误差反向更新输入层和隐藏层之间的权重和偏置<sup>[13]</sup>。误差的计算通常使用均方误差或交叉熵等损失函数。

## 4 SSA-BP (Sparrow Search Algorithm-BP) 神经网络算法模型

### 4.1 麻雀搜索算法(Sparrow Search Algorithm, SSA)

BP 神经网络的训练过程中容易陷入局部最优解, 且易出现过拟合、对初始权值敏感性较强等问题。为了提高预测精度, 本研究采用 SSA-优化 BP 神经网络, 克服其易陷入局部最优、收敛速度慢等问题。

SSA 是一种基于群体智能的优化算法, 通过模拟麻雀群体的搜索行为, 寻找最优解<sup>[14-15]</sup>。SSA 的核心思想是“觅食 - 反捕食 - 加入”, 即先在环境中搜索食物, 警戒躲避天敌敌害, 同时在种群搜寻猎物的时候也有新成员加入群体。算法如下:

#### 步骤 1 更新发现者位置

在 SSA 算法中, 适应度值高的个体具有更高的搜索优先级。这些高适应度值的个体不仅承担寻找食物的责任, 且为其他个体提供探索方向, 从而提高整个种群的觅食效率。每次迭代中, 这些高适应度值的个体位置更新速度更快, 以便更快地靠近食物源。通过这种方式, SSA 算法可以在搜索空间中寻找到更优秀的解决方案, 该过程为:

$$A_{i,j}^{t+1} = \begin{cases} A_{i,j}^t \cdot e^{\frac{i}{a \cdot L}} & R_2 < ST \\ A_{i,j}^t + Q \cdot L & R_2 \geq ST \end{cases} \quad (7)$$

式中:  $A_{i,j}^t$ — $t$  时刻  $i, j$  个个体位置;  $Q$ —服从正态分

布的随机数;  $L$ —单位行向量;  $a$  取  $0 \sim 1$  之间的随机值;  $N$ —最大迭代次数。

当 SSA 算法中的随机数  $R_2 < ST$  时, 表示目前的觅食环境中没有捕食者, 可放心进行广泛搜索。在此情况下, 发现者可全面探索周围环境, 以寻找更多食物来源。但当  $R_2 \geq ST$  时, 这意味着种群中已出现捕食者, 此时种群需要飞到安全的地方重新开始觅食。

#### 步骤 2 更新加入者位置

当某个体找到了食物, 周围其他个体受到诱惑, 聚集到这里寻找食物。该过程如下:

$$A_{i,j}^{t+1} = \begin{cases} Q \cdot e^{\frac{A'_{\text{worst}} - A'}{i^2}} & i > \frac{n}{2} \\ A_p^{t+1} + |A'_{i,j} - A_p^{t+1}| \cdot H + L & i \leq \frac{n}{2} \end{cases} \quad (8)$$

式中:  $A'_{\text{worst}}$ —适应度最低的个体值。  $H$ —包含 1 和 -1 的行向量。

当  $i > n/2$  时, 第  $i$  个加入者的适应度值较低, 意味着在当前环境中没有获得足够的食物, 需要前往其他区域寻找更多的食物和能量。

#### 步骤 3 更新警惕者位置

当天敌对于整个种群构成巨大威胁时, 处于群体边缘的个体为了逃离威胁, 寻求更加安全的栖息地, 将会进行迅速的转移和迁移, 甚至会主动寻找具有更好栖息条件的区域。该过程如下:

$$A_{i,j}^{t+1} = \begin{cases} A_{\text{best}}^t + \beta \cdot |A'_{i,j} - A_{\text{best}}^t| & f_i > f_{\text{best}} \\ A_{i,j}^t + K \cdot \left( \frac{|A'_{i,j} - A_{\text{worst}}^t|}{(f_i - f_{\text{worst}}) + \varepsilon} \right) & f_i = f_{\text{best}} \end{cases} \quad (9)$$

式中:  $\beta$ —服从正态分布的随机数;  $K$  取  $1 \sim -1$  之间的随机数;  $f$ —个体适应度值。

当个体的适应度值  $f_i$  高于整个种群的平均适应度值  $f_{\text{best}}$  时, 表明其位于种群边缘, 处于易受捕食者攻击的危险状态。这些个体将积极寻找安全区域并迅速向其移动。相反, 当个体的适应度值  $f_i$  等于整个种群的平均适应度值  $f_{\text{best}}$  时, 这表明其意识到潜在威胁, 并开始采取措施以减少被捕食风险。个体将通过调整移动方向和步长控制参数  $K$  来尽可能地靠近其他个体, 以增加存活几率。

### 4.2 SSA-BP 神经网络

在使用 SSA 优化神经网络的过程中, 首先将 BP 神经网络的权值和偏置作为搜索空间中的个体, 然

后利用SSA的搜索策略进行权值和偏置调整。具体流程如下:

步骤1:定义搜索代数N、麻雀群体规模n、每只麻雀的位置以及目标函数;

步骤2:计算其适应度值,适应度值表示该组权值和阈值对应的BP神经网络的性能指标;

步骤3:对适应度值进行排序,并按照顺序将麻雀种群划分为发现者和加入者两个群体;

步骤4:更新发现者位置;

步骤5:更新加入者位置;

步骤6:更新警戒者位置;

步骤7:根据终止条件,更新每个麻雀的最优位置和群体最优位置,如果满足条件,则结束搜索,输出群体最优位置所对应的权值和阈值组合;否则,回到第2步继续搜索。

步骤8:将最优权值和阈值组合输入至神经网络中,实现回归预测。

## 5 模型对比

对煤质数据库进行筛选,剔除空缺值与偏差较大值,共有3370条有效数据。按煤种分类后共有无烟煤454种、贫煤438种、烟煤1771种、褐煤707种。随机选择444种无烟煤、428种贫煤、1761种烟煤、697种褐煤作为训练样本,用于分煤种建模;其余的10种无烟煤、10种贫煤、10种烟煤、10种褐煤共40个样本作为测试样本,用于分煤种检验模型精确度。

3种模型的预测结果与真实值的对比如表3所示。表中 $C_{ad}$ 为空气干燥基碳元素含量真实值, $C_{ad,LR}$ 为线性回归模型预测值, $C_{ad,BP}$ 为BP神经网络模型预测值, $C_{ad,SSA-BP}$ 为SSA-BP神经网络模型预测值。 $\delta_{LR}$ 、 $\delta_{BP}$ 、 $\delta_{SSA-BP}$ 分别为线性回归预测值、BP神经网络预测值、SSA-BP神经网络预测值与真实值的相对误差(%)。对10种无烟煤进行空气干燥基碳元素含量预测,线性回归模型的相对误差范围在1.71%~20.48%,平均相对误差9.00%;BP神经网络模型的相对误差范围0.11%~0.55%,平均相对误差0.21%;SSA-BP神经网络模型的相对误差范围为0.01%~0.94%,平均相对误差0.18%。对10种贫煤进行空气干燥基碳元素含量预测,上述3种模型的相对误差范围分别为1.57%~39.46%,0.92%~18.52%和0.56%~28.00%,平均相对误差为12.14%,7.01%和3.16%。对10种烟煤进行空气干燥基碳元素含量预测,上述3种模型的相对误差范围分别为2.79%~13.22%,0.32%~6.12%和0.02%~4.19%,平均相对误差为7.75%,1.43%和1.15%。对10种褐煤进行空气干燥基碳元素含量预测,上述3种模型的相对误差为0.83%~7.33%,0.01%~5.89%和0~1.37%,平均相对误差为4.69%,1.40%和0.69%。线性回归模型、BP神经网络模型、SSA-BP神经网络模型对所有煤种计算的平均相对误差分别为8.40%,2.51%,1.30%。线性回归模型预测值误差较大,BP神经网络模型预测值误差较小,SSA-BP神经网络模型预测值误差最小。

表3 不同煤种空气干燥基碳元素含量预测结果

Tab. 3 Prediction results of air dry base carbon element content in different coal types

煤种	矿区	$V_{daf}$ /%	$M_{ad}$ /%	$A_{ad}$ /%	$Q_{net,ar}/$ $\text{MJ}\cdot\text{kg}^{-1}$	$C_{ad}$ /%	$C_{ad,LR}$ /%	$\delta_{LR}$ /%	$C_{ad,BP}$ /%	$\delta_{BP}$ /%	$C_{ad,SSA-BP}$ /%	$\delta_{SSA-BP}$ /%
无烟煤	晋城	9.78	0.62	9.08	31.06	87.74	83.41	4.94	87.88	0.16	88.02	0.32
	晋城	8.31	3.10	14.58	29.01	79.76	75.90	3.63	79.65	0.24	79.75	0.03
	阳泉	9.06	0.68	14.25	29.05	81.36	78.41	17.99	81.56	0.11	81.34	0.05
	阳泉	7.83	0.66	10.18	27.89	78.62	83.05	5.64	78.75	0.16	78.73	0.15
	涟邵	9.05	2.02	24.50	23.78	81.29	66.67	20.48	81.20	0.14	81.33	0.94
	涟邵	9.39	1.94	25.40	22.03	82.66	65.73	4.84	82.54	0.14	81.88	0.01
	石炭井	7.51	0.66	10.24	30.23	78.04	83.12	6.51	77.97	0.09	78.02	0.02
	石炭井	6.94	0.70	8.00	30.18	76.43	85.60	12.00	76.19	0.31	76.52	0.12
	石炭井	6.77	0.74	9.92	30.44	74.55	83.67	1.71	74.96	0.17	74.50	0.09

续表 3

煤种	矿区	$V_{\text{daf}}$ /%	$M_{\text{ad}}$ /%	$A_{\text{ad}}$ /%	$Q_{\text{net,ar}} /$ $\text{MJ} \cdot \text{kg}^{-1}$	$C_{\text{ad}}$ /%	$C_{\text{ad,LR}}$ /%	$\delta_{\text{LR}}$ /%	$C_{\text{ad,BP}}$ /%	$\delta_{\text{BP}}$ /%	$C_{\text{ad,SSA-BP}}$ /%	$\delta_{\text{SSA-BP}}$ /%
贫煤	焦作	7.18	0.99	14.80	27.85	76.94	78.26	12.24	77.07	0.55	76.87	0.07
	六枝	17.44	2.30	22.00	25.41	47.30	65.97	39.46	53.77	18.44	50.63	7.04
	六枝	18.87	1.43	19.17	27.93	52.05	72.04	10.03	66.82	4.48	66.62	4.21
	芙蓉	15.82	2.82	35.25	19.31	53.30	50.59	2.27	54.35	18.52	52.87	7.20
	芙蓉	13.96	2.38	37.57	18.55	51.44	48.57	5.08	51.19	4.16	51.15	0.81
	罗城	10.01	2.94	45.10	15.72	46.14	41.51	4.67	44.69	3.37	44.20	0.78
	龙口	17.47	9.80	17.47	19.17	53.71	52.49	4.92	50.08	3.89	57.58	3.02
	英岗岭	12.45	1.18	36.82	19.50	53.18	50.70	9.45	52.49	8.22	52.77	6.33
	林东	12.76	0.92	34.68	19.38	53.02	50.41	1.57	54.12	3.44	54.62	3.46
烟煤	坊子	18.97	3.70	37.14	17.98	52.32	47.38	38.41	52.24	4.62	49.01	28.00
	广旺	19.27	1.72	37.94	19.83	52.26	51.44	5.58	50.51	0.92	50.45	0.56
	枣庄	33.29	1.06	9.17	29.03	79.84	74.19	10.57	78.85	0.48	78.88	0.78
	枣庄	32.31	0.70	8.48	29.48	79.50	75.37	9.43	80.18	1.65	80.39	1.61
	枣庄	37.25	2.12	16.60	23.07	66.34	61.30	13.22	66.57	6.12	66.69	4.19
	霍州	36.13	0.79	9.86	28.21	79.82	72.27	7.48	76.33	1.39	77.43	0.14
	西山	20.96	0.51	9.61	27.97	79.52	74.21	6.72	80.51	1.10	79.42	1.45
	一平浪	24.88	0.66	10.04	27.54	79.85	72.76	3.34	80.17	0.32	80.37	0.59
	鸡西	29.36	1.01	12.77	29.29	76.03	74.00	7.75	76.22	0.33	75.67	0.02
褐煤	南桐	22.07	1.12	13.26	26.87	76.03	70.86	2.79	76.25	1.09	76.04	1.50
	双鸭山	37.88	2.47	16.30	25.64	66.86	65.45	9.87	67.41	0.45	67.62	0.69
	峰峰	29.99	1.50	21.98	24.53	66.34	62.98	6.28	65.58	1.41	66.03	0.57
	抚顺	48.08	3.28	14.34	25.27	65.79	62.51	4.05	65.50	0.01	66.26	0.89
	抚顺	52.63	3.38	30.04	19.71	52.23	48.40	6.11	50.71	0.69	52.10	1.00
	兗州	42.62	2.63	10.84	27.25	70.80	67.93	4.99	70.81	0.45	71.43	0.71
	新汶	41.15	2.15	7.74	27.03	74.11	69.58	3.50	74.62	0.21	74.85	0.53
	双鸭山	40.25	3.37	22.62	23.64	60.87	58.74	5.85	61.00	0.66	60.55	0.95
	徐州	40.57	1.66	30.36	20.18	55.02	51.80	0.83	54.66	0.17	54.50	0.00
6 碳排放计算结果与对比	辽源	47.71	13.17	13.31	20.06	53.66	53.22	3.24	53.75	5.89	53.66	0.36
	龙口	45.02	13.55	17.15	19.75	50.01	51.63	7.33	52.95	2.91	49.83	0.24
	舒兰	55.13	12.52	40.52	11.30	31.61	30.59	3.24	31.17	1.40	31.88	0.84
	开滦	42.02	0.96	55.30	11.21	32.74	30.21	7.72	32.20	1.65	33.19	1.37

检测点位应避开弯头、阀门等断面急剧变化的部位，检测断面烟气流速应大于 5 m/s。

选取负荷相对平稳、负荷较为波动、升负荷、降负荷 4 种典型工况，比较烟气检测  $\text{CO}_2$  排放值与 3 种模型原料侧碳排放计算方法所得  $\text{CO}_2$  排放值。

## 6.1 电厂煤质数据收集

该电厂百万机组典型工作日所用煤种工业分析数据如表 4 所示。

选取某电厂 1 000 MW 燃煤机组为研究对象，开展原料侧碳排放和烟气侧碳排放实时计算对比。该百万机组装备有国内某试验研究院烟气碳排放检测系统。烟气检测是指通过检测仪器在燃煤烟气的烟囱总排口检测烟气中的  $\text{CO}_2$  浓度、烟道烟气流速、烟气流量，从而计算出燃煤烟气中  $\text{CO}_2$  总排放量。

表4 某电厂百万机组入炉煤工业分析数据

Tab. 4 Proximate analysis data of 1 000 MW unit's feeding coal in a power plant

煤种	$M_t/\%$	$M_{ad}/\%$	$A_{ar}/\%$	$V_{daf}/\%$	$Q_{net,ar}/\text{MJ} \cdot \text{kg}^{-1}$
贫瘦煤 I	7.1	0.63	25.89	16.63	22.59
贫瘦煤 II	7.4	0.77	27.60	17.05	21.83
高硫煤	8.4	2.16	27.44	40.81	19.46
印尼煤	36.4	19.62	3.82	52.31	15.62
中昌 398	8.6	2.88	20.07	38.67	21.58
中硫煤	26.3	13.66	7.35	46.39	19.03

表4中 $M_t$ 、 $M_{ad}$ 、 $A_{ar}$ 和 $V_{daf}$ 分别为全水份、空气干燥基水分、收到基灰分、干燥无灰基挥发分的质量分数。试验在该厂两个典型工作日进行,工作日内灰渣含碳量分别为4.56%和4.29%。

## 6.2 稳定负荷工况

根据该电厂典型工作日所用煤种工业分析数据,使用线性回归、BP神经网络、SSA-BP神经网络模型预测各煤种空气干燥基碳元素含量。分别选取低负荷、中负荷、高负荷3种平稳运行工况,其中低负荷平稳运行锅炉负荷均值为304.33 MW,负荷波动标准差为2.05;中负荷平稳运行锅炉负荷均值为501.23 MW,负荷波动标准差为0.63;高负荷平稳运行锅炉负荷均值为901.78 MW,负荷波动标准差为2.08。将空气干燥基碳元素含量预测值转化为收到基碳元素含量后,代入燃煤碳排放核算方法计算燃煤碳排放。

平稳负荷3种工况下采用线性回归、BP神经网络、SSA-BP神经网络模型计算碳排放与烟气检测法计算碳排放对比如图2所示。

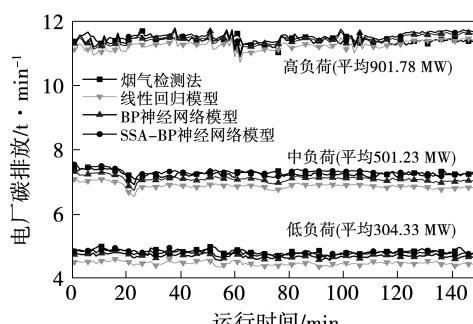


图2 平稳工况下电厂碳排放

Fig. 2 Carbon emissions in a power plant under stationary load

低负荷平稳运行工况下,采用线性回归、BP神经网络、SSA-BP神经网络模型预测值计算碳排放与烟气检测法计算碳排放RMSE分别为0.35,0.08和0.07;中负荷平稳运行工况下上述3种模型计算碳排放与烟气检测法计算碳排放RMSE分别为0.87,0.37和0.09;高负荷平稳运行工况下上述3种模型计算碳排放与烟气检测法计算碳排放RMSE为0.23,0.19和0.17。3种负荷平稳工况下,SSA-BP神经网络模型核算碳排放均与烟气检测法测得碳排放值偏差最小,其次为BP神经网络模型,线性回归模型核算碳排放值偏差最大。

## 6.3 升负荷工况

选取某电厂升负荷稳步上升阶段,该阶段机组负荷从394.44 MW持续上升到946.71 MW。将预测所得空气干燥基碳元素含量转化为收到基碳元素含量后,代入燃煤碳排放核算方法计算燃煤碳排放。升负荷工况下3种模型与烟气检测法计算碳排放对比如图3所示。

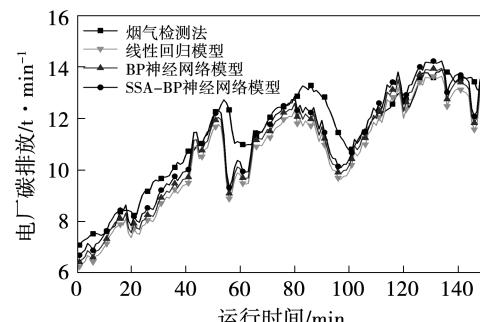


图3 升负荷工况下电厂碳排放

Fig. 3 Carbon emissions in a power plant under load up

升负荷工况下,上述3种模型计算碳排放与烟气检测法计算碳排放RMSE为1.00,0.84和0.71。SSA-BP神经网络模型核算碳排放与烟气检测法测得碳排放值偏差最小,其次为BP神经网络模型,线性回归模型核算碳排放值偏差最大。

## 6.4 降负荷工况

选取某电厂升负荷稳步下降阶段,该阶段机组负荷从949.19 MW持续下降到515.77 MW。将预测所得空气干燥基碳元素含量转化为收到基碳元素含量后,代入燃煤碳排放核算方法计算燃煤碳排放。降负荷工况下采用3种模型计算碳排放与烟气检测法计算碳排放对比如图4所示。

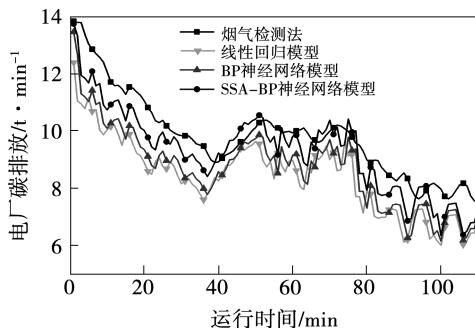


图 4 降负荷工况下电厂碳排放

Fig. 4 Carbon emissions in a power plant under load down

降负荷工况下,上述3种模型计算碳排放与烟气检测法计算碳排放RMSE为1.43,1.24和0.73。SSA-BP神经网络模型核算碳排放均与烟气检测法测得碳排放值偏差最小,其次为BP神经网络模型,线性回归模型核算碳排放值偏差最大。

## 6.5 波动负荷工况

选取某电厂负荷波动明显阶段,该阶段负荷平均值为588.53 MW,负荷波动标准差为50.73。将预测所得空气干燥基碳元素含量转化为收到基碳元素含量后,代入燃煤碳排放核算模型计算燃煤碳排放。波动负荷工况下采用3种模型计算碳排放与烟气检测法计算碳排放对比,结果如图5所示。

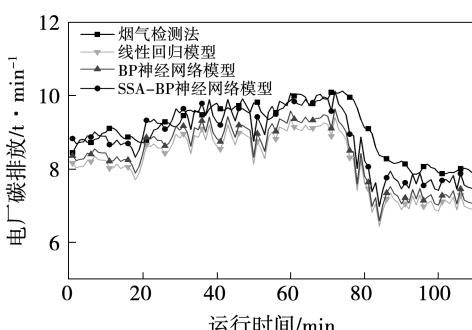


图 5 波动负荷工况下电厂碳排放

Fig. 5 Carbon emissions in a power plant under fluctuating load

波动负荷工况下,上述3种模型计算碳排放与烟气检测法计算碳排放RMSE为1.33,1.15和0.93。SSA-BP神经网络模型核算碳排放均与烟气检测法测得碳排放值偏差最小,其次为BP神经网络模型,线性回归模型核算碳排放值偏差最大。

## 6.6 电厂24 h内碳排放总量

分别采用3种模型计算某电厂百万机组典型工作日24 h内碳排放总量并与锅炉烟气碳排放监测值进行对比,结果如图6所示。

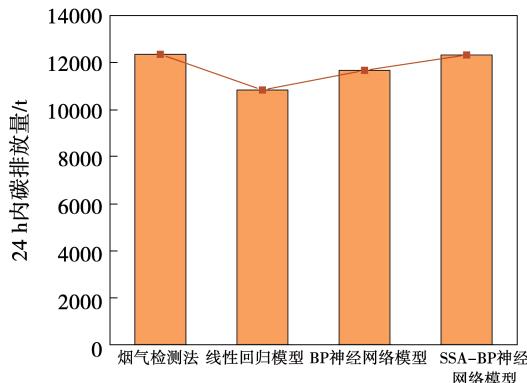


图 6 某电厂24 h内总碳排放

Fig. 6 Total carbon emissions in a power plant within 24 hours

由图6可知,该电厂百万机组采用3种模型计算碳排放总量与烟气检测法测得碳排放总量相比,线性回归模型、BP神经网络模型和SSA-BP神经网络模型相比烟气检测法的相对偏差分别为12.28%,5.52%和0.22%。采用线性回归模型计算碳排放总量结果偏低,偏差较大;采用BP神经网络模型计算碳排放总量结果与烟气侧测量较为接近;采用SSA-BP神经网络模型计算碳排放总量结果与烟气侧测量最为接近。

## 7 结论

(1) 根据煤种工业分析数据,通过线性回归、BP神经网络、SSA-BP神经网络模型预测煤碳元素分析含碳量,可为电厂原料侧碳排放计算提供基础数据。其中,线性回归模型、BP神经网络模型、SSA-BP神经网络模型的相对误差分别为8.40%,2.51%和1.30%。

(2) 3种模型可以用于电厂原料侧碳排放计算。相比烟气侧测量法,在负荷连续波动工况下,上述3种模型燃煤连续碳排放计算值与烟气检测值偏差最大;升负荷、降负荷工况下,上述3种模型燃煤连续碳排放计算值与烟气检测值偏差次之;稳定负荷工况下,上述3种模型燃煤连续碳排放计算值与烟气检测值偏差最小。

(3) 使用线性回归、BP神经网络、SSA-BP神经网络模型计算电厂典型工作日内碳排放总量,并与烟气检测法测得燃煤碳排放进行比较,燃煤总碳排放计算值与烟气检测法测得燃煤碳排放之间相对偏差分别为12.28%,5.52%和0.22%。总体上,SSA-BP神经网络模型具有较好的煤质预测精度,基于其优化的神经网络模型可与烟气侧核算相互补充,为燃煤电厂碳核算提供有力参考。

## 参考文献:

- [1] 王萍萍,赵永椿,张军营,等.双碳目标下燃煤电厂碳计量方法研究进展[J].洁净煤技术,2022,28(10):170–183.  
WANG Ping-ping,ZHAO Yong-chun,ZHANG Jun-ying,et al. Research progress on carbon measurement methods of coal-fired power plants under the background of carbon neutrality [J]. Clean Coal Technology,2022,28(10):170–183.
- [2] 胡道明,李蛟,杜晓东,等.碳中和背景下含氢综合能源系统碳排放和经济性分析[J].热能动力工程,2023,38(4):111–120.  
HU Dao-ming,LI Jiao,DU Xiao-dong,et al. Carbon emissions and economic analysis of integrated energy system containing hydrogen using for carbon neutrality [J]. Journal of Engineering for Thermal Energy and Power,2023,38(4):111–120.
- [3] 马凯,韩文涛,丁艺,等.煤种对燃煤电厂碳排放经济性的影响研究[J].热能动力工程,2018,33(9):142–146,85.  
MA Kai,HAN Wen-tao,DING Yi,et al. Study on the influence of coal on the carbon emission economy of coal-fired power plant [J]. Journal of Engineering for Thermal Energy and Power,2018,33(9):142–146,85.
- [4] 高建强,宋铜铜,杨东江.燃煤发电机组碳排放折算方法研究与应用[J].热力发电,2020,49(2):88–92.  
GAO Jian-qiang,SONG Tong-tong,YANG Dong-jiang. Research and application of carbon emission conversion method for coal-fired generating units [J]. Thermal Power Generation,2020,49(2):88–92.
- [5] 岳鹏程,孟志东,梁晓瑜.煤质工业分析转换元素分析数学模型研究[J].中国计量学院学报,2013,24(3):327–330.  
YUE Peng-cheng,MENG Zhi-dong,LIANG Xiao-yu. Study on mathematical models for quick-calculating ultimate analysis from proximate analysis [J]. Journal of China University of Metrology,2013,24(3):327–330.
- [6] 郑生,左兆迎,吴尚睿,等.煤炭低位发热量与其他工业分析元素关系研究[J].中国检验检测,2020,28(4):22–25.  
ZHENG Sheng,ZUO Zhao-ying,WU Shang-rui,et al. Study on the relationship between low calorific value of coal and other industrial analytical elements [J]. China Inspection Body & Laboratory,2020,28(4):22–25.
- [7] 丁皓轩,吴震坤,唐文,等.煤炭工业分析转化元素分析计算式改进与回归模型[J].洁净煤技术,2021,27(S2):170–174.  
DING Hao-xuan,WU Zhen-kun,TANG Wen,et al. Calculation formula improvement and regression model for calculate ultimate analysis from proximate analysis of coal [J]. Clean Coal Technology,2021,27(S2):170–174.
- [8] 赵新木,王承亮,吕俊复,等.基于BP神经网络的煤粉锅炉飞灰含碳量研究[J].热能动力工程,2005,20(2):158–162,216.  
ZHAO Xin-mu,WANG Cheng-liang,LYU Jun-fu,et al. The investigation of carbon content in fly ash for a BP neural network-based pulverized coal-fired boiler [J]. Journal of Engineering for Thermal Energy and Power,2005,20(2):158–162,216.
- [9] 国家标准委.碳达峰碳中和标准体系建设指南[Z].  
Standardization Administration. Standard system construction guide for carbon peak and carbon neutrality[Z].
- [10] GB/T 5751–2009,中国煤炭分类[S].  
GB/T 5751–2009,Chinese coal classification[S].
- [11] 沈跃云,高小涛,孟硕.600 MW墙式燃烧锅炉氮氧化物排放浓度与主要运行因素的多元线性回归研究[J].热能动力工程,2011,26(6):726–731,776–777.  
SHEN Yue-yun,GAO Xiao-tao,MENG Shuo. Study of a multivariable linear regression of the  $\text{NO}_x$  emissions concentration and main operating factors of a 600 MW wall-type boiler [J]. Journal of Engineering for Thermal Energy and Power,2011,26(6):726–731,776–777.
- [12] MASON K,DUGGAN J,HOWLEY E. Forecasting energy demand, wind generation and carbon dioxide emissions in Ireland using evolutionary neural networks [J]. Energy,2018,155:705–720.
- [13] 李鹏辉,刘冉,余廷芳.基于支持向量机和BP神经网络的燃煤锅炉 $\text{NO}_x$ 排放预测[J].热能动力工程,2016,31(10):104–108,129–130.  
LI Peng-hui,LIU Ran,YU Yan-fang. Modeling of  $\text{NO}_x$  emission from coal fired boiler based on intelligent algorithm [J]. Journal of Engineering for Thermal Energy and Power,2016,31(10):104–108,129–130.
- [14] 谭增强,牛拥军,李元昊,等.基于麻雀算法和深度极限学习机的 $\text{NO}_x$ 预测研究[J].中国电机工程学报,2022,42(S1):187–192.  
TAN Zeng-qiang,NIU Yong-jun,LI Yuan-hao,et al. Research on  $\text{NO}_x$  prediction of thermal power plant based on SSA-DELM [J]. Proceedings of the CSEE,2022,42(S1):187–192.
- [15] 冯磊华,张杰,詹毅.基于改进麻雀搜索算法和核极限学习机的电站锅炉燃烧优化[J].热力发电,2022,51(9):96–102.  
FENG Lei-hua,ZHANG Jie,ZHAN Yi. Combustion optimization of utility boilers based on ISSA and KELM [J]. Thermal Power Generation,2022,51(9):96–102. (姜雪梅 编辑)