文章编号:1674-7607(2026)02-0174-09 DOI:10.19805/j.cnki.jcspe.2026.240709

基于BO-TPE优化ERT模型的污泥焚烧SO_2排放预测

罗 松[1], 王丽花[2], 王 飞[1]
(1. 浙江大学 能源高效利用全国重点实验室,浙江杭州 310027;
2. 上海城投污水处理有限公司,上海 201203)

摘 要: 为提高污泥焚烧过程中SO_2排放的预测精度以优化焚烧与烟气处理工况,提出了一种高效稳定的SO_2排放混合预测模型。首先,以鼓泡流化床污泥焚烧系统为研究对象,从火焰图像中提取静态与动态火焰特征,并结合分布式控制系统(DCS)参数构建输入特征,SO_2排放浓度设为模型输出。然后,利用互信息(MI)确定SO_2与各输入特征的最优滞后时间并据此进行数据重组。最终构建基于树结构的贝叶斯优化(BO-TPE)的极端随机树(ERT)预测模型,并与多种主流预测模型进行性能对比。结果表明:基于BO-TPE优化的ERT模型相关系数R^2为0.93,平均绝对百分比误差(MAPE)小于3%,适用于污泥焚烧系统SO_2排放的在线预测与过程优化控制。

关键词: SO_2排放浓度预测; 污泥焚烧; 火焰图像; 极端随机树; 优化算法
中图分类号:X701 **文献标志码:**A **学科分类号:**470.30

Prediction of SO_2 Emission Concentration from Sludge Incineration Based on ERT Model with BO-TPE Optimization

LUO Song[1], *WANG Lihua*[2], *WANG Fei*[1]
(1. State Key Laboratory of Clean Energy Utilization, Zhejiang University, Hangzhou 310027, Zhejiang Province, China;
2. Shanghai Chengtou Waste Water Treatment Co., Ltd., Shanghai 201203, China)

Abstract: To enhance the prediction accuracy of SO_2 emissions during sludge incineration process and optimize incineration and flue gas treatment conditions, an efficient and stable hybrid prediction model for SO_2 emissions was prorosed. First, using a bubbling fluidized bed sludge incineration system as the research subject, static and dynamic flame features were extracted from flame images and the input features were set combined with distributed control system (DCS) parameters, while SO_2 emission concentration was set as the model output. Subsequently, mutual information (MI) was employed to determine the optimal lag time between SO_2 and each input feature, guiding data reorganization. Finally, the extremely randomized trees (ERT) model based on Bayesian optimization-TPE (BO-TPE) was constructed and compared with multiple mainstream prediction models. Results show that the BO-TPE-optimized ERT model achieves correlation

收稿日期:2024-11-14 **修订日期:**2025-01-14
基金项目:浙江省科技计划资助项目(2024C03129)
作者简介:罗 松(2001—),男,江西宜春人,博士研究生,研究方向为基于机器视觉的焚烧炉燃烧诊断研究。
王 飞(通信作者),男,教授,博士, E-mail: wangfei@zju.edu.cn。

coefficient R^2 of 0.93 with mean absolute percentage error(MAPE) below 3%, making it suitable for online prediction and process optimization control of SO_2 emissions in sludge incineration systems.

Key words: SO_2 emission concentration prediction; sludge incineration; flame image; extremely randomized trees; optimization algorithm

污泥的主要处置方法包括卫生填埋、土地利用、焚烧和建筑材料，相比于其他处置方法，焚烧具有能够显著减少污泥体积、去除有害物质并实现能量回收的优点[1]。然而，污泥焚烧产生的 SO_2 等污染物对环境和人体健康都有潜在的危害。因此，对污泥焚烧产生的 SO_2 进行及时有效的监测和控制是保护环境和公共健康的重要措施。控制污染物排放的一个先决条件是对污染物排放的准确监控，传统经验公式估算难以推广，现场实测又耗时耗力。因此，寻找准确、快速的方法对污泥焚烧产生的 SO_2 排放量进行预测尤为必要。

基于数据驱动的 SO_2 排放浓度预测方法已被广泛使用。张砺彦等[2]基于人工神经网络建立了大型燃煤电厂的 SO_2 排放浓度预测模型。Krzywanski 等[3]建立了不同类型循环流化床锅炉 SO_2 排放浓度的广义预测模型。金秀章等[4]提出了一种基于最大相关最小冗余算法和蜉蝣算法优化正则化极限学习机的出口 SO_2 质量浓度预测模型。倪绍佑等[5]建立了主成分分析与 BP 神经网络结合使用的燃煤锅炉 SO_2 排放浓度预测模型，预测相对误差约为 5%。王琦等[6]建立了基于改进向量加权平均优化的双向长短期记忆神经网络模型，用于预测燃煤电厂的 SO_2 排放浓度。尽管上述模型预测性能表现良好，但存在计算复杂度高的问题。当模型复杂度较高而训练样本数量有限时，神经网络模型更容易过拟合[7]。

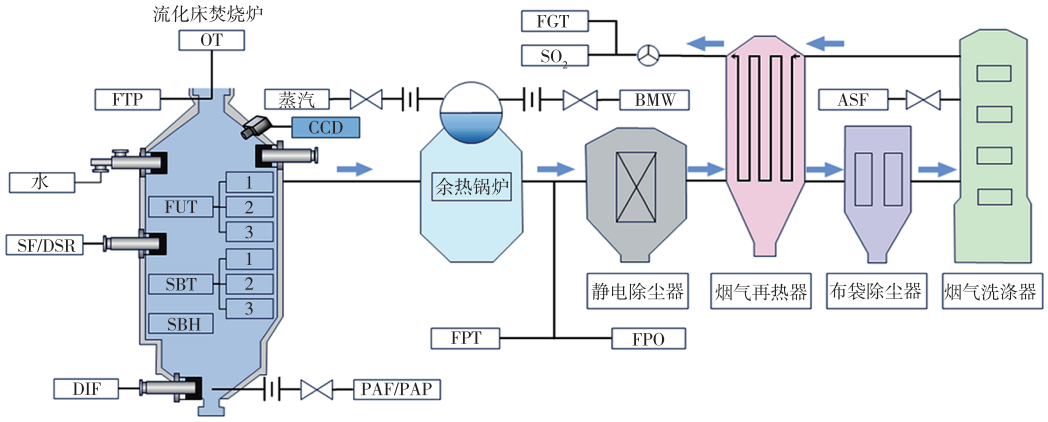
以上针对 SO_2 排放浓度进行预测的研究，模型输入变量基本都是分布式控制系统(DCS)参数或基于 DCS 参数提取的深度特征，忽略了火焰特性信息，模型的输入特征信息不足，并且模型大多基于神经网络，存在计算效率和鲁棒性低的问题。

为了弥补现有技术的不足，本文提出了基于树结构的贝叶斯(BO-TPE)优化的极端随机树(ERT)模型来预测污泥焚烧炉的 SO_2 排放浓度。首先，基于 CCD 相机拍摄焚烧炉火焰图像，从火焰图像中提取火焰静态特征和动态特征数据，并与 DCS 参数组成数据集。然后，基于互信息算法分析 SO_2 与其他特征之间的滞后关系，并根据结果重组数据。最后，建立了基于 BO-TPE 优化的 ERT 模型，采用评估指标评估该模型，并与随机森林(random forest，RF)、支持向量回归(support vector regression，SVR)、BP 等预测模型进行对比。

1　污泥焚烧炉与数据预处理

1.1　污泥焚烧炉

如图 1 所示，污泥按一定干湿比投入鼓泡式流化床焚烧炉，焚烧炉底部通入一次风和柴油辅助污泥流化态燃烧，CCD 于炉膛顶部拍摄火焰图像。污泥燃烧产生的烟气经余热锅炉回收热量，随后经过静电除尘器、烟气再热器、布袋除尘器和烟气洗涤器，最后通过烟气再热器排出。



OT—出口温度；FTP—炉顶压力；SF—污泥流量；DSR—干泥占比；FUT—上部温度；SBT—砂层温度；SBH—砂层高度；DIF—柴油流量；PAF—一次风量；PAP—一次风压；FPT—烟气管路温度；FPO—烟气管路氧含量；BMW—锅炉补水量；FGT—烟气温度；ASF—碱液流量。

图 1　污泥焚烧流程图

Fig. 1　The flow chart of sludge incineration

1.2 火焰特征提取

在本研究中，CCD 相机被置于焚烧炉炉顶拍摄火焰图像，为了提高镜头对炉内亮度变化下的即时反应能力，选用可调光圈的高温针孔镜头，镜头端面采用耐高温蓝宝石级石英玻璃。基于图像处理技术对火焰图像进行特征提取，提取出平均亮度、亮度标准差、平均脉动频率、脉动面积率、平均速度、平均角度 6 个火焰特征，如图 2 所示。

(1) 平均亮度

将原始火焰 RGB 图像转化成 HSV 图像，提取出 V 通道分量，火焰原始图像和火焰 V 通道图像分别如图 2(a)和图 2(b)所示。V 代表亮度，用来表示颜色明亮的程度，可以反映火焰的温度情况。从图 2 可以看出，炉膛火焰外的这些背景并不会随着火焰的周期性变化而发生变化。为了消去该炉膛背景带来的不良影响，基于双峰法确定图像分割阈值[8]，提取出火焰区域并计算其中的平均亮度，计算公式如下：

$$V_{\mathrm{mean}}=\sum_{i=1}^{G}V_i/G \tag{1}$$

式中：V_{mean} 为亮度平均值；V_i 为第 i 个像素的亮度；G 为火焰区域中的像素个数。

(2) 亮度标准差

亮度标准差可以衡量亮度的离散程度，在一定程度上反映火焰温度的不均匀性。亮度标准差 s 计算公式如下：

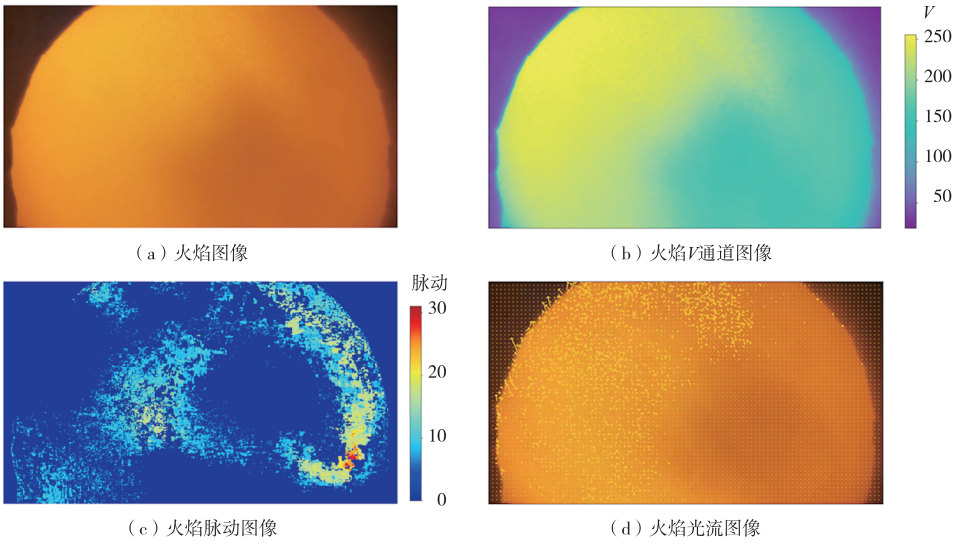
$$s=\sqrt{\frac{1}{G-1}\sum_{i=1}^{G}(V_i-V_{\mathrm{mean}})^2} \tag{2}$$

(3) 平均脉动频率

通过提取当前时刻前 5 s 内的所有图像，计算得到平均亮度序列。用离散傅里叶变换对平均亮度序列进行处理，并去掉直流分量。在火焰燃烧过程中，火焰脉动频率组成非常多，不能简单提取出一个主要频率来替代脉动频率，所以本文采用功率谱平均脉动频率来进行分析。计算公式为

$$F_{\mathrm{m}}=\frac{\sum_{i=1}^{N-1}f_iP(f_i)}{\sum_{i=1}^{N-1}P(f_i)} \tag{3}$$

式中：F_{m} 为平均脉动频率，Hz；f_i 为频域曲线频率分量；$P(f_i)$ 为频域曲线幅值分量的平方。



(a) 火焰图像　(b) 火焰V通道图像　(c) 火焰脉动图像　(d) 火焰光流图像

图 2 基于图像处理的火焰特征提取

Fig. 2 Extraction of flame features based on image processing

(4) 脉动面积率

基于三帧差法计算脉动面积率以减少噪声干扰[9]。首先获取相邻的 3 张图片，分别提取出 V 通道数据，前两帧与后两帧分别作差分计算，得到的 2 次差分结果作逻辑或运算，最终得到 V 值脉动数据，其反映了像素点亮度的变化情况，火焰脉动如图 2(c)所示。定义脉动大小超过 3 的像素为显著脉动像素，其数量与火焰区域的像素数量之比即为脉动面积率。计算公式如下：

$$M=|V^{(i-2)}-V^{(i-1)}|\ \underline{\vee}\ |V^{(i-1)}-V^{(i)}| \tag{4}$$

$$P_i=\frac{\sum_{i=1}^{m}\sum_{j=1}^{n}L(M_{i,j})}{N},M_{i,j}>\theta \tag{5}$$

式中：P_i 为脉动面积率；$V^{(i)}$ 为第 i 帧的 V 通道数据；M 为 V 值脉动数据；$L(\cdot)$ 为阶跃函数；θ 为脉动阈值；N 为火焰区域像素个数。

(5) 平均速度

基于 L-K 光流法计算平均速度。污泥焚烧的

火焰比较稳定，相邻帧的火焰图像亮度变化缓慢，适用于 L-K 光流法计算[10]。由 L-K 光流法可以得到梯度方程为

$$V_x u + V_y v + V_t = 0 \tag{6}$$

式中：u、v 分别为 x、y 方向的速度；V_x、V_y 和 V_t 分别为亮度在 x、y 和 t 上的偏导。

计算得到的火焰光流图如图 2(d)所示。取 10×10 的窗口，那么窗口内的每个点都认为有一样的移动方向。将所有的点($P_1 \sim P_{100}$)应用于梯度方程得到：

$$\begin{bmatrix} V_x(P_1) & V_y(P_1) \\ V_x(P_2) & V_y(P_2) \\ \vdots & \vdots \\ V_x(P_{100}) & V_y(P_{100}) \end{bmatrix} \begin{bmatrix} u & v \end{bmatrix} = - \begin{bmatrix} V_t(P_1) \\ V_t(P_2) \\ \vdots \\ V_t(P_{100}) \end{bmatrix} \tag{7}$$

基于最小二乘法求解式(7)即可得出(u, v)，速度计算公式为

$$w = \sqrt{u^2 + v^2} \tag{8}$$

最终计算火焰区域所有像素点的速度后取平均值，即为当前时刻平均速度。

(6) 平均角度

单个像素点的速度方向 φ 计算公式为

$$\varphi = \frac{180}{\pi} \arctan \frac{v}{u} \tag{9}$$

最终计算火焰区域所有像素点的速度方向取平均值即为当前时刻平均角度。

1.3　数据统计

研究表明，污泥焚烧生成 SO_2 主要与污泥组分、焚烧温度和氧量有关[11-12]，一般污泥中 80% 以上的硫以有机硫形式存在，污泥焚烧时含硫化合物先分解、挥发，生成反应活性很高的中间产物，这些中间产物又进一步被氧化，转变成 SO_2 气体。随着焚烧温度升高，污泥中含硫有机化合物越来越不稳定，更多的硫被分解、析出，最终导致 SO_2 排放浓度增加。氧量越高，污泥越容易完全燃烧，产生的 SO_2 也就越多。在脱硫系统中，喷洒碱液可以有效降低 SO_2 排放[13]。亮度可以反映火焰的温度高低，从而间接影响 SO_2 生成。本研究结合现场运行情况，采集与产生 SO_2 相关的 DCS 参数，与火焰特征参数组成总数据集，表 1 给出了各变量的情况。选择的变量几乎涵盖污泥焚烧的全过程，包含污泥流量、柴油流量等可人为调控的直接变量，还有炉顶压力、砂层温度等反映焚烧过程的状态参数，还有平均亮度、平均脉动频率等火焰特征参数。污泥处理厂难以对污泥成分进行实时测量，同时污泥的来源相对稳定，成分变化不大，因此没有把污泥的硫、钙含量等参数作为输入变量。各变量的数据范围较宽，其箱线图如图 3 所示。

表 1　DCS、火焰特征和 SO_2 的数据统计

Tab. 1　Data statistics of DCS, flame feature and SO_2

序号	参数	下限值	上限值
1	污泥质量流量 SF/(t·h^{-1})	3.69	6.38
2	干泥占比 DSR	0.26	0.50
3	一次风量 PAF/(m^3·h^{-1})	10 448.14	11 039.31
4	碱液体积流量 ASF/(L·h^{-1})	88.47	99.71
5	锅炉补水量 BMW/(t·h^{-1})	2.99	9.62
6	柴油体积流量 DIF/(L·h^{-1})	0	264.50
7	一次风压 PAP/kPa	18.26	19.12
8	砂层高度 SBH/mm	1 713.28	1 775.86
9	炉顶压力 FTP/Pa	−672.83	−413.14
10	上部温度 1 FUT_1/℃	747.85	840.42
11	上部温度 2 FUT_2/℃	728.23	891.44
12	上部温度 3 FUT_3/℃	816.63	898.70
13	砂层温度 1 SBT_1/℃	779.23	869.47
14	砂层温度 2 SBT_2/℃	772.20	842.14
15	砂层温度 3 SBT_3/℃	773.17	870.24
16	出口温度 OT/℃	732.28	801.91
17	烟气管路温度 FPT/℃	257.46	273.29
18	烟气管路氧体积分数 FPO/%	6.76	12.47
19	烟气温度 FGT/℃	58.50	66.00
20	平均亮度 AB	114.87	185.39
21	亮度标准差 BSD	4.42	1 042.28
22	平均脉动频率 APF/Hz	0.33	2.81
23	脉动面积率 PAR	0	0.30
24	平均速度 AS	0.07	1.57
25	平均角度 AA	−2.44	2.34
26	SO_2 排放质量浓度 $\rho(SO_2)$/(mg·m^{-3})	11.18	45.51

2　模型建立

2.1　互信息计算方法

模型的 25 个输入变量与 SO_2 排放浓度在不同程度上呈非线性关系。互信息(MI)算法可以分析了这些变量与 SO_2 排放浓度之间的相关性。MI 根据信息熵原理量化了 2 个随机变量 X 和 Y 之间的相关性[14]。2 个离散随机变量 X 和 Y 的互信息可以由如下公式[15]表示：

$$H(X) = -\sum_{x \in X} P(x) \ln P(x) \tag{10}$$

$$H(X,Y) = -\sum_{x \in X} \sum_{y \in Y} P(x,y) \ln P(x,y) \tag{11}$$

$$I(X,Y) = \sum_{x \in X} \sum_{y \in Y} P(x,y) \ln \frac{P(x,y)}{P(x)P(y)} \tag{12}$$

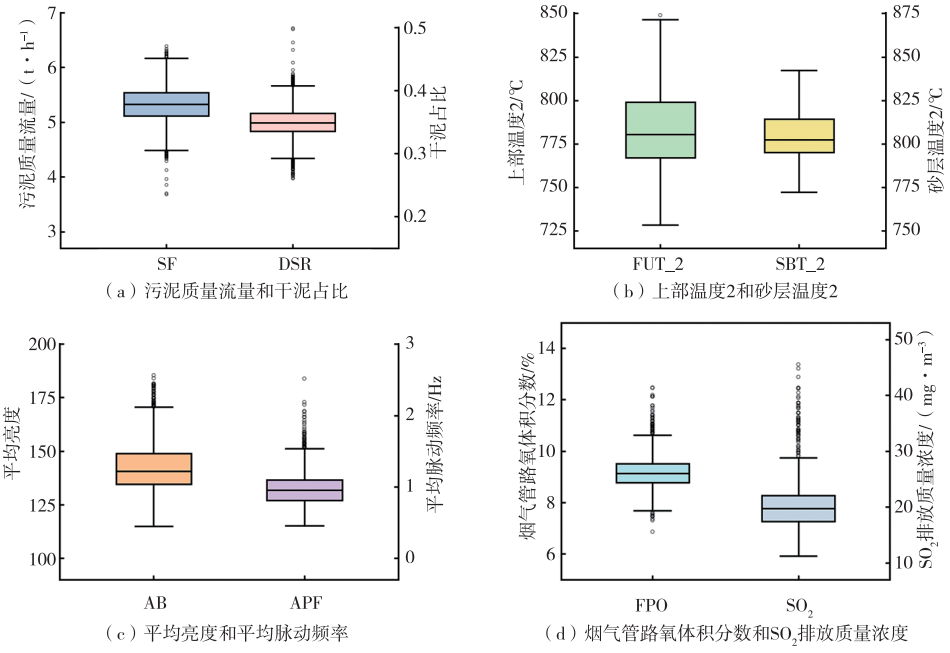
式中：$H(X)$为离散随机变量 X 的信息熵；$H(X,Y)$为 X 和 Y 的联合熵；$I(X,Y)$为 X 和 Y 的互信息；

$P(x)$和$P(y)$分别为 X 和 Y 的边际概率密度函数；$P(x,y)$为 X 和 Y 的联合概率密度函数。

在 X 和 Y 是连续随机变量的情形下，求和被替换成了二重定积分：

$$I(X,Y)=\int_Y\int_X P(x,y)\ln\left(\frac{P(x,y)}{P(x)P(y)}\right)\mathrm{d}x\mathrm{d}y \tag{13}$$

然而，在给定的数据集上通常无法知道连续变量的概率分布，其概率密度函数也就无法获得。



（a）污泥质量流量和干泥占比　（b）上部温度2和砂层温度2

（c）平均亮度和平均脉动频率　（d）烟气管路氧体积分数和SO_2排放质量浓度

图 3　部分特征数据的箱线图

Fig. 3　Box plots of partial feature data

Kraskov 等[16]提出了基于 k-近邻估计的 2 个连续随机变量的互信息计算方法，该计算方法在 Python的 Sklearn 库中已经封装为函数，可以直接调用。本研究就是采用这种方法来计算不同特征与 SO_2 的互信息。

2.2　数据预处理

根据实际经验，模型的 25 个输入变量与 SO_2 排放浓度之间存在时间滞后，依靠机理分析或实验测量来估计滞后时间可靠性不足。本文采用 MI 来确定滞后时间。数据为 $D=\{x(k),\ y(k)\}$，$x(k)=[x_1(k),\ x_2(k),\ \cdots,x_{25}(k)]$，$y(k)$为 SO_2 排放浓度，k 的范围$[0,\ n-1]$。每一组特征都能与 $y(k)$计算得到一个互信息。以 $x_1(k)$和 $y(k)$为例，当滞后时间为 0 min 时，$x_1(k)$和 $y(k)$的互信息为$I_1(0)$，当滞后时间为 τ 时，$x_1(k)$与 $y(k)$的数据重合时间的部分为$(x_1(0),\ x_1(n-\tau))$和$(y(\tau),\ y(n))$，计算得到的互信息为 $I_1(\tau)$。因此，计算滞后时间为 0～$\tau_{\max}$的互信息大小，互信息最大对应的滞后时间即为最佳滞后时间。最终可得到最佳互信息序列$I=[I_1(\tau_1),\ I_2(\tau_2),\ \cdots,\ I_{25}(\tau_{25})]$和滞后时间序列 $\tau=[\tau_1,\ \tau_2,\ \cdots,\ \tau_{25}]$。以滞后时间序列 τ 中的最大滞后时间作为基准，对数据进行重组，如图 4 所示。

根据污泥焚烧炉的实际运行经验，$\tau_{\max}$设置为 10 min。通过 MI 算法分析了各个特征与 SO_2 排放浓度之间的相关性及滞后时间，结果如表 2 所示。可以看出，炉膛上部温度(3 个测点)、砂层温度(3 个测点)、氧体积分数与 SO_2 排放浓度的相关性最大，MI 都在 0.70 以上，这比较符合 SO_2 的生成机理。各个特征与 SO_2 的滞后时间也基本能和焚烧流程对应上。从污泥流量砂层温度再到炉膛上部温度、烟气温度，滞后时间基本遵循逐级递减的规律。

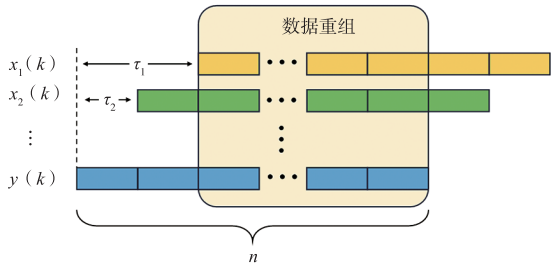


图 4　基于互信息的数据重组

Fig. 4　Data reorganization based on MI

在模型训练之前，数据还需要进行标准化。数据标准化是一个常用的数据预处理操作，通过将特征缩放到相同尺度，以消除特征间的量纲差异[17]，

表 2　互信息与滞后时间分析

Tab. 2　Analysis of MI and lag time

参数	MI	滞后时间/min	参数	MI	滞后时间/min
污泥质量流量 SF	0.69	4	砂层温度 2 SBT_2	0.94	5
干泥占比 DSR	0.66	7	砂层温度 3 SBT_3	0.92	6
一次风量 PAF	0.47	4	出口温度 OT	0.88	1
碱液体积流量 ASF	0.61	6	烟气管路温度 FPT	0.70	2
锅炉补水量 BMW	0.50	4	烟气管路氧体积分数 FPO	0.70	2
柴油体积流量 DIF	0.70	5	烟气温度 FGT	0.97	3
一次风压 PAP	0.53	4	平均亮度 AB	0.46	3
砂层高度 SBH	0.56	1	亮度标准差 BSD	0.23	3
炉顶压力 FTP	0.47	4	平均脉动频率 APF	0.33	3
上部温度 1 FUT_1	0.78	2	脉动面积率 PAR	0.24	5
上部温度 2 FUT_2	0.99	2	平均速度 AS	0.36	5
上部温度 3 FUT_3	0.71	3	平均角度 AA	0.02	3
砂层温度 1 SBT_1	0.95	5			

对模型的训练效率和准确性有着积极作用。数据标准化公式为

$$x' = \frac{x - \mu}{\sigma} \tag{14}$$

式中：x' 为特征标准化后的数据；μ 为原始数据的均值；σ 为原始数据的标准差。

2.3　基于 BO-TPE 优化的极端随机树模型

基于树的集成方法是监督分类和回归问题的流行方法[18]。集成方法通过训练学习出多个估计器，把所有估计器的结果整合起来当成最后的结果输出，这提升了模型的通用性与鲁棒性，比单个估计器拥有更好的预测性能[19]。RF 是经典的模型，能够处理高维数据，无需降维处理也有很好的预测效果[20]。ERT 是 RF 的一种变体，它在构建决策树时引入了更多的随机性，并使用所有样本来构建决策树并随机选择特征集，且训练速度更快[21]。

构建一个有效的机器学习模型除了需要确定适当的算法外，还需要调整其超参数(HP)来获得最佳的模型架构。现在主流的超参数优化方法有：无模型算法、基于梯度的优化算法、基于贝叶斯的优化算法和元启发式算法[22]。无模型算法原理简单，但计算效率低下。基于梯度的优化算法只能优化连续型超参数，并且容易陷入局部最优。贝叶斯优化算法基于先前评估的结果确定下一个超参数值，以减少不必要的评估并提高效率，其中 BO-TPE 适合处理各种类型的超参数和目标函数分布，算法适应性更强。元启发式算法比其他超参数优化(hyperparameter optimization，HPO)算法更复杂，需要更多的计算资源，并且引入了额外的超参数，通常在复杂的优化问题上表现良好。

本文所采用的基于树的集成方法，需要优化的超参数是离散型的棵数和深度，优化问题较为简单，因此采用 BO-TPE 作为 SO_2 排放浓度预测模型的超参数优化方法。优化目标为 $-R^2$(即相关系数 R^2 的负值，用于将优化问题转化为最小化问题)。优化过程中采取 5 折交叉验证，以在模型评估时更好地平衡偏差与方差，从而提升模型在不同数据集上的泛化能力。

2.4　模型评估指标

为了综合评价各个模型的预测性能，本研究采用相关系数(R^2)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)3 个评价指标。R^2 越接近 1，RMSE 和 MAPE 越小，模型的预测性能越好。其数学定义式为

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(\hat{y}_i - y_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \tag{15}$$

$$E_{\mathrm{RMSE}} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \tag{16}$$

$$E_{\mathrm{MAPE}} = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i - y_i}{y_i}\right| \times 100\% \tag{17}$$

式中：n 为样本数量；y_i 为样本中的 SO_2 排放浓度测量值；$\bar{y}_i$ 为样本中的 SO_2 排放浓度平均值；$\hat{y}_i$ 为 SO_2 排放浓度预测值。

3　实验结果与讨论

3.1　实验设计

基于第 2 节所述提取 19 个 DCS 参数、6 个火

焰特征参数和对应时刻的 SO_2 排放浓度数据，实验数据采样间隔为 1 min。为了提高模型的泛化能力和普遍性，采集了 4 个不同时间段的数据。基于 2.1 和 2.2 节所述对数据进行重组，在每个时间段选取 500 组数据，构成 4 个数据集，分别用 D_1、D_2、D_3、D_4 表示。每个数据集按照 3∶1∶1的比例分成训练集、测试集和验证集。训练集、测试集中的数据是随机选取的，以提高模型训练数据的多样性。验证集的数据是选取连续一段时间的，以验证模型在实际运行下的预测性能。将每组数据集划分后的训练集和测试集分别合并起来用于模型训练和测试。

3.2 模型结果与分析

各个模型的预测性能如表 3 所示。在 4 个基础模型中，ERT、SVR 和 BP 模型的 R^2 都接近 0.9，RF 模型的 R^2 偏低，只有不到 0.85。ERT 模型的 R^2、RMSE 和 MAPE 都要优于其他模型，在训练时间上仅仅略长于 SVR 模型。相比于 RF 模型，ERT 模型在构建决策树时通过随机选择分割点而不是寻找最优分割点，从而减少了计算量，因此其训练效率显著高于 RF 模型。BP 神经网络训练时，每个 epoch 都需要通过反向传播算法不断调整权重和偏置，以最小化损失函数，因此计算量大，训练时间显著长于其他模型。

BO-TPE 优化后的 ERT 模型性能也得到全面提升。相比于未优化的 ERT 模型，其 R^2 提升 0.8%，RMSE 降低 5%，MAPE 降低 14%，训练时间也降低 31%，在训练效率提高的基础上，模型预测性能显著提高，验证了 BO-TPE 的有效性。

表 3 不同模型的预测性能

Tab. 3 Prediction performance of different models

模型	R^2	E_{RMSE}/(mg·m^{-3})	E_{MAPE}/%	时间/s
RF	0.845 4	1.730 6	4.241 3	1.341 5
ERT	0.927 0	1.189 5	3.356 9	0.242 7
SVR	0.890 9	1.454 1	4.299 6	0.221 5
BP	0.902 2	1.376 6	4.146 4	10.165 7
ERT(BO-TPE 优化)	0.934 4	1.127 2	2.901 3	0.166 5

基于 BO-TPE 优化的 ERT、SVR 和 BP 模型在 4 组验证集上的预测性能如图 5 所示。由于 RF 模型性能较差，并没有一起比较。可以看出，基于 BO-TPE 优化的 ERT 模型 SO_2 排放质量浓度预测值与真实值非常接近，能够准确反映出 SO_2 的变化趋势，在出现较大波动时，也能拟合得很好。基于 BO-TPE 优化的 ERT 模型在 4 组验证集上的预测效果都很好，表现出良好的泛化能力，能够适应不同工况下的预测需求。

为了进一步验证基于 BO-TPE 优化的 ERT 模型性能，图 6 对比了不同模型的真实值和预测值之间的误差。基于 BO-TPE 优化的 ERT 模型的预测误差集中在[−2,2]内。随着误差的增大，频数呈现逐渐减小的趋势。总体来看，SVR 和 BP 模型的预测误差分布与基于 BO-TPE 优化的 ERT 模型相似，但 RF 和 BP 模型存在更多预测偏差很大的样本

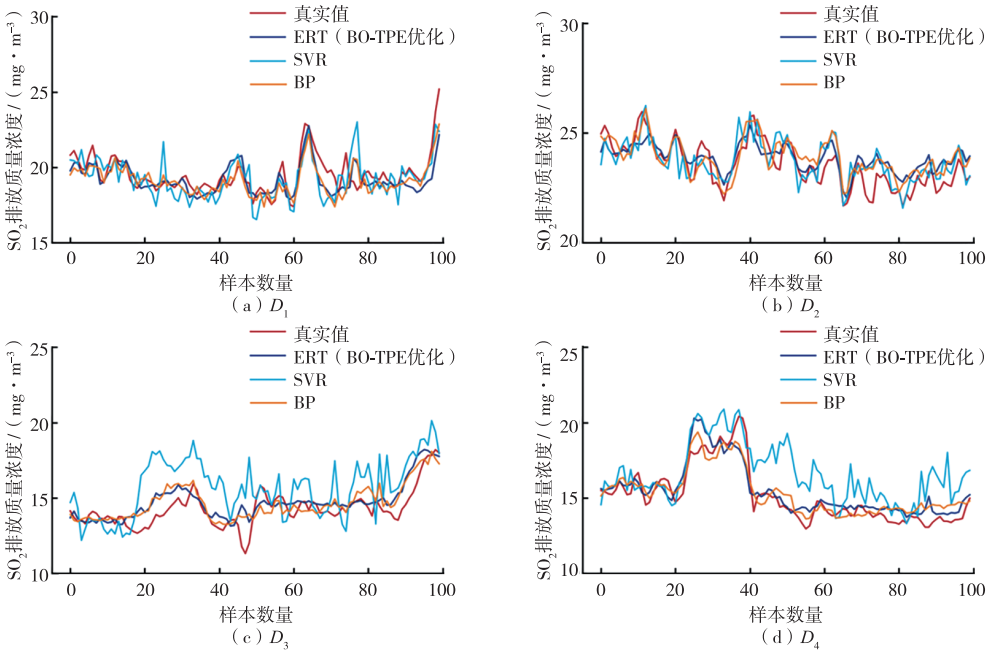


图 5 不同模型的 SO_2 排放质量浓度预测

Fig. 5 Prediction of SO_2 emission concentration for different models

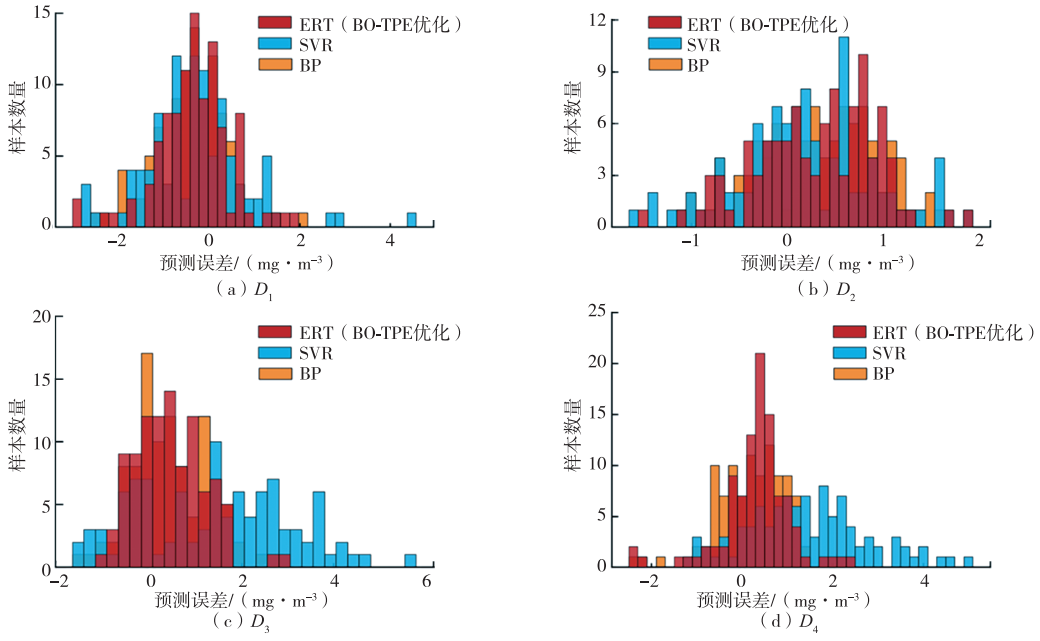


图 6　不同模型的预测误差

Fig. 6　Prediction errors of different models

点，并且在相同误差范围内，SVR 和 BP 模型的样本点也更可能多。因此，进一步证明了基于 BO-TPE 优化的 ERT 模型预测精度更高。

4　结论

本文提出了一种先进的混合模型用于预测污泥焚烧炉的 SO_2 排放浓度。首先，从火焰图像中提取焚烧火焰的静态与动态特征，并将其与 DCS 参数融合形成模型输入；随后，基于互信息确定 SO_2 与输入特征的滞后时间并完成数据重组；最终构建基于 BO-TPE 优化的 ERT 模型，并与多种先进预测方法进行了对比。

实验结果表明，ERT 模型在预测精度和计算效率方面表现优异。经 BO-TPE 优化后，模型的 R^2 提高了约 0.8%，RMSE 降低了 5%，MAPE 降低了 14%，说明优化策略显著提升了模型性能，验证了所提混合预测模型的有效性与适用性。

参考文献：

[1] ZHANG Junhui, SUN Guang, LIU Jingyong, et al. Co-combustion of textile dyeing sludge with cattle manure: assessment of thermal behavior, gaseous products, and ash characteristics [J]. Journal of Cleaner Production, 2020, 253: 119950.

[2] 张砺彦，麦永强，张月辉，等. 基于神经网络的大型燃煤电厂 SO_2 和 NO_x 的污染物预测模型[J]. 热力发电，2008，37(10)：9-13.
ZHANG Liyan, MAI Yongqiang, ZHANG Yuehui, et al. Prediction model for pollutants SO_2 and NO_x from large-scale coal-fired power plant based on neural network[J]. Thermal Power Generation, 2008, 37(10): 9-13.

[3] KRZYWANSKI J, CZAKIERT T, BLASZCZUK A, et al. A generalized model of SO_2 emissions from large- and small-scale CFB boilers by artificial neural network approach: part 1. the mathematical model of SO_2 emissions in air-firing, oxygen-enriched and oxy-combustion CFB conditions [J]. Fuel Processing Technology, 2015, 137: 66-74.

[4] 金秀章，刘岳，赵文杰，等. 基于 mRMR 和 MA-RELM 的火电厂出口 SO_2 质量浓度预测[J]. 动力工程学报，2022，42(7)：664-670，676.
JIN Xiuzhang, LIU Yue, ZHAO Wenjie, et al. Prediction of SO_2 mass concentration at outlet of the thermal power plant based on mRMR and MA-RELM [J]. Journal of Chinese Society of Power Engineering, 2022, 42(7): 664-670, 676.

[5] 倪绍佑，姚晨蓬，陈玲红，等. 基于后向传播神经网络的循环流化床锅炉 SO_2 排放预测分析[J]. 能源工程，2021(6)：31-37.
NI Shaoyou, YAO Chenpeng, CHEN Linghong, et al. Prediction analysis of SO_2 emissions from circulating fluidized bed boiler based on BP neural network[J]. Energy Engineering, 2021(6): 31-37.

[6] 王琦，柴宇唤，王鹏程，等. 基于改进 INFO-Bi-LSTM 模型的 SO_2 排放质量浓度预测[J]. 动力工程学报，2024，44(4)：641-649.
WANG Qi, CHAI Yuhuan, WANG Pengcheng,

et al. Prediction of SO_2 emission mass concentration based on improved INFO-Bi-LSTM algorithm[J]. Journal of Chinese Society of Power Engineering, 2024, 44(4): 641-649.

[7] BEJANI M M, GHATEE M. A systematic review on overfitting control in shallow and deep neural networks[J]. Artificial Intelligence Review, 2021, 54(8): 6391-6438.

[8] XIE Kai, CUI Yunjing, WANG Chunlin, et al. Study on threshold selection method of continuous flame images of spray combustion in the low-pressure chamber[J]. Case Studies in Thermal Engineering, 2021, 26: 101195.

[9] QIU Guoqing, LIU Shuai, CAO Dongmei, et al. Flame recognition based on video image[J]. Applied Mechanics and Materials, 2014, 687-691: 3604-3607.

[10] KWAK D K, RYU J K. A study on fire detection using deep learning and image filtering based on characteristics of flame and smoke[J]. Journal of Electrical Engineering & Technology, 2023, 18(5): 3887-3895.

[11] 李畅. 城市污泥焚烧及污染物排放特性研究[D]. 保定: 华北电力大学, 2015.

[12] 房文轩. 污泥干化与流化床焚烧试验研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.

[13] LARKI I, ZAHEDI A, ASADI M, et al. Mitigation approaches and techniques for combustion power plants flue gas emissions: a comprehensive review[J]. Science of the Total Environment, 2023, 903: 166108.

[14] BOSTANI H, SHEIKHAN M. Hybrid of binary gravitational search algorithm and mutual information for feature selection in intrusion detection systems[J]. Soft Computing, 2017, 21(9): 2307-2324.

[15] ESKAFI M, KOWSARI M, DASTGHEIB A, et al. Mutual information analysis of the factors influencing port throughput[J]. Maritime Business Review, 2021, 6(2): 129-146.

[16] KRASKOV A, STÖGBAUER H, GRASSBERGER P. Estimating mutual information[J]. Physical Review E, 2004, 69(6): 066138.

[17] ELEN A, AVUÇLU E. Standardized variable distances: a distance-based machine learning method[J]. Applied Soft Computing, 2021, 98: 106855.

[18] SAGI O, ROKACH L. Ensemble learning: a survey[J]. WIREs Data Mining and Knowledge Discovery, 2018, 8(4): e1249.

[19] DONG Xibin, YU Zhiwen, CAO Wenming, et al. A survey on ensemble learning[J]. Frontiers of Computer Science, 2020, 14(2): 241-258.

[20] RIGATTI S J. Random forest[J]. Journal of Insurance Medicine, 2017, 47(1): 31-39.

[21] ACOSTA M R C, AHMED S, GARCIA C E, et al. Extremely randomized trees-based scheme for stealthy cyber-attack detection in smart grid networks[J]. IEEE Access, 2020, 8: 19921-19933.

[22] YANG Li, SHAMI A. On hyperparameter optimization of machine learning algorithms: theory and practice[J]. Neurocomputing, 2020, 415: 295-316.