

城市固体废物焚烧过程炉温的鲁棒加权异构特征集成预测模型

郭京承^{1,2} 严爱军^{1,2,3} 汤健¹

摘要 针对城市固体废物 (Municipal solid waste, MSW) 焚烧过程, 数据具有异常值和特征变量维度高时, 炉温预测模型的准确性和泛化能力欠缺的挑战性问题, 提出一种鲁棒加权异构特征集成建模方法, 用于建立城市固体废物焚烧过程炉温预测模型. 首先, 依据焚烧过程机理将高维特征变量划分为异构特征集合, 并采用互信息和相关系数综合评估每组异构特征集合的贡献度; 其次, 采用基于混合 t 分布的鲁棒随机配置网络 (Stochastic configuration network, SCN) 构建基模型, 同时确定训练样本的惩罚权重; 最后, 设计一种鲁棒加权负相关学习 (Negative correlation learning, NCL) 策略, 实现基模型的鲁棒同步训练. 使用国内某城市固体废物焚烧厂的炉温历史数据, 对该方法进行测试. 测试结果表明, 该方法建立的炉温预测模型在准确性和泛化能力方面具有优势.

关键词 城市固体废物焚烧, 炉温预测, 异构特征集成, 鲁棒建模, 随机配置网络

引用格式 郭京承, 严爱军, 汤健. 城市固体废物焚烧过程炉温的鲁棒加权异构特征集成预测模型. 自动化学报, 2024, 50(1): 121–131

DOI 10.16383/j.aas.c230042

Robust Weighted Heterogeneous Feature Ensemble Prediction Model of Temperature in Municipal Solid Waste Incineration Process

GUO Jing-Cheng^{1,2} YAN Ai-Jun^{1,2,3} TANG Jian¹

Abstract Aiming at the challenging problems of the deficient accuracy and generalization ability of the furnace temperature prediction model when the municipal solid waste (MSW) incineration process data has abnormal values and high dimensionality of feature variables, a robust weighted heterogeneous feature ensemble modeling method is proposed to establish the furnace temperature prediction model of the municipal solid waste incineration process. Firstly, the high dimensional feature variables are divided into heterogeneous feature sets according to the incineration process mechanism, and the contribution of each heterogeneous feature set is evaluated by the mutual information and correlation coefficient. Secondly, a robust stochastic configuration network (SCN) with the t mixture distribution is employed to construct base models, and penalty weights of training samples are determined at the same time. Finally, the robust weighted negative correlation learning (NCL) strategy is used to realize the synchronous training of base models. Comparative experiments are carried out using the historical furnace temperature data of a municipal solid waste incineration plant in China. The results show that the furnace temperature prediction model established by the proposed method performs more favourably in accuracy and generalization.

Key words Municipal solid waste incineration, furnace temperature prediction, heterogeneous feature ensemble, robust modeling, stochastic configuration network (SCN)

Citation Guo Jing-Cheng, Yan Ai-Jun, Tang Jian. Robust weighted heterogeneous feature ensemble prediction model of temperature in municipal solid waste incineration process. *Acta Automatica Sinica*, 2024, 50(1): 121–131

收稿日期 2023-02-09 录用日期 2023-04-13

Manuscript received February 9, 2023; accepted April 13, 2023
国家自然科学基金 (62373017, 62073006), 北京市自然科学基金 (4212032) 资助

Supported by National Natural Science Foundation of China (62373017, 62073006) and Beijing Natural Science Foundation of China (4212032)

本文责任编辑 孙秋野

Recommended by Associate Editor SUN Qiu-Ye

1. 北京工业大学信息学部 北京 100124 2. 数字社区教育部工程研究中心 北京 100124 3. 城市轨道交通北京实验室 北京 100124

1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. Engineering Research Center of Digital Community, Ministry of Education, Beijing 100124 3. Beijing Laboratory for Urban Mass Transit, Beijing 100124

焚烧可以实现城市固体废物 (Municipal solid waste, MSW) 的减量化、无害化和资源化, 是 MSW 处理的主要方式之一^[1-2]. 在 MSW 焚烧过程中, 炉温是评估焚烧过程运行合格与否的关键指标之一. 为了保证焚烧过程中二噁英气体被完全分解, 炉温需要持续控制在 850 °C 以上^[3]. 然而, 在焚烧炉内的高温环境下, 炉内热电偶存在易损坏和精度低等问题, 并且由于焚烧过程具有滞后性, 操作人员难以及时判断炉温变化情况. 因此, 构建炉温预测模型, 对指导与优化 MSW 焚烧过程稳定运行, 具有

现实意义。

目前,炉温预测模型主要包括机理模型和数据驱动模型两类。机理模型是根据焚烧过程中固、气相反应的物理化学变化以及能量、动量守恒等先验知识,确定炉排速度、一次和二次风机风量等操作变量与炉温的映射关系^[4-5]。虽然这类模型在可靠性和解释性方面具有优势,但焚烧过程机理的复杂性和 MSW 热值的不确定性导致机理模型的预测精度无法保证。而以人工神经网络为代表的驱动模型,无需获取焚烧过程中的复杂机理和先验知识,通过运行数据,学习输入变量与炉温之间的映射关系^[6-7]。这类模型的训练算法普遍采用误差反向传播算法,存在收敛速度慢和容易陷入局部最优等问题。随机学习技术通过随机分配隐含层输入权重和偏置,将神经网络模型训练问题转化为求解线性优化问题^[8],可以实现神经网络的快速训练。Wang 等^[9]引入一种依赖于数据的监督机制,递增式地快速构建神经网络模型,从而获得了具有万能逼近性质的随机配置网络(Stochastic configuration network, SCN)模型。该模型在参数建模领域的成功应用,为构建焚烧过程炉温预测模型提供了技术支持^[10-12]。然而,焚烧过程数据存在异常值和特征变量维度高的现象,使得 SCN 模型的准确性和泛化能力仍有待提升。

在提升 SCN 模型对异常值的鲁棒性方面,文献[13]将核密度估计方法与 M 估计相结合,并采用加权最小二乘法计算模型输出权重,提升了 SCN 模型对异常值的鲁棒性。文献[14]使用最大相关熵准则度量训练样本的惩罚权重,在提升 SCN 模型鲁棒性方面,有不错的效果。此外,工业过程的复杂性和不确定性导致单一分布难以恰当描述样本中异常值的分布情况,文献[15]和文献[16]分别采用将高斯分布与若干个拉普拉斯分布的混合分布以及混合 t 分布,作为训练样本的异常值分布,均在不同程度上缓解了异常值对建模性能的影响。但随着特征变量维度的增加,单个 SCN 模型的泛化能力难以保证。

在具有高维特征变量情况下,虽然特征选择与特征提取技术通过选择部分重要特征或提取高维数据中的主成分来构建数据驱动模型^[17-18],但可能损失高维特征数据中蕴含的部分信息,从而影响模型准确性。文献[19]提出一种异构特征神经网络集成的框架,该框架以 SCN 为基模型,并通过负相关学习(Negative correlation learning, NCL)策略^[20],实现了基模型之间的同步训练,在高维特征数据建模方面,具有不错的应用前景。但该方法未考虑各组异构特征对输出变量的重要性以及异常值对模型准确性的影响。

基于上述分析,本文综合考虑 MSW 焚烧过程数据中同时存在异常值和高维特征变量两种情况,提出一种用于构建 MSW 焚烧过程炉温预测模型的鲁棒加权异构特征集成建模方法。本文主要贡献如下:1)综合焚烧过程运行机理以及焚烧炉排构造,将高维特征变量划分为异构特征集合,应用后续集成建模;2)在异构特征集成框架的基础上,采用互信息和皮尔逊相关系数(后续简称“相关系数”),确定每组异构特征对输出变量的贡献度,从而明确每个基模型的重要性;3)采用文献[16]的鲁棒 SCN 构建基模型,并综合各个基模型的训练过程确定样本惩罚权重;4)设计一种鲁棒加权 NCL 策略,实现基模型之间的鲁棒同步训练。采用焚烧过程的炉温历史数据,验证了本文方法的有效性和优越性。

1 MSW 焚烧过程

MSW 焚烧过程的工艺流程如图 1 所示。MSW 焚烧过程由固体废物储运系统、固体废物焚烧系统、余热锅炉系统、蒸汽发电系统和烟气处理系统 5 个系统组成,各系统的具体功能如下:

1) 固体废物储运系统。生活中产生的 MSW 由固体废物清运车送至固体废物储蓄池内。MSW 具有高水分、低热值的特点,需要在储蓄池内静置 3~10 天,以完成 MSW 的脱水、发酵环节,并由抓手送至焚烧炉的进料器,进行焚烧。

2) 固体废物焚烧系统。预处理后的 MSW 由进料器送入干燥炉排。在一次风对流换热以及炉内高温辐射的作用下,完成 MSW 的水分干燥过程;干燥后的 MSW 经过 2 段燃烧炉排,在高温作用下,析出挥发分,并与一次风中的氧气在一燃室燃烧,未充分燃烧的挥发分气体在二次风的作用下,进一步燃烧;MSW 中的固定碳在燃烬段炉排燃烧。

3) 余热锅炉系统和蒸汽发电系统。由 MSW 焚烧产生的高温气体在烟气通道内,依次通过过热器、蒸发器和省煤器,实现烟气余热回收,回收的热量将冷却水转化为主蒸汽,用于汽轮机发电,从而实现焚烧过程的资源化。

4) 烟气处理系统。焚烧过程产生的烟气将分别通过脱酸反应、布袋除尘设备实现烟气处理,并在引风机的作用下,由烟囱排出。

在焚烧工艺流程中,炉温通常指一燃室烟气的平均温度,是衡量焚烧过程运行是否正常的关键指标之一。目前,现场采用热电偶实时测量炉温的变化情况。然而,在炉内高温环境下,热电偶存在精度低和易损坏等问题。并且,炉温变化具有滞后性,即调整过程变量后,炉内的热电偶难以及时反映炉




图 1 MSW 焚烧过程工艺流程图

Fig.1 MSW incineration process flow chart

温的变化情况. 基于上述炉温的特点可知, 构建炉温预测模型, 对保证焚烧过程安全稳定运行, 具有现实意义.

从构建炉温预测模型的角度看, 影响炉温的机理反应主要包括水分干燥、挥发分析出、挥发分燃烧等多阶段的物理化学变化^[21]. 这导致构建炉温预测模型涉及的特征变量数量众多, 变量明细如表 A1 所示. 采用特征选择或特征提取方法可以降低预测模型的输入变量维度, 提升模型的泛化能力, 但降低特征维度会损失过程数据中蕴含的部分信息. 另外, 焚烧过程数据中包含的异常值会导致炉温预测的准确性降低. 因此, 本文的研究重点是在焚烧过程数据具有高维特征变量和异常值的情况下, 提升炉温预测模型的准确性和泛化能力.

2 鲁棒加权异构特征集成建模方法

针对焚烧过程数据同时存在异常值和高维特征变量的特点, 提出一种鲁棒加权异构特征集成建模方法, 着重提升 MSW 焚烧过程炉温预测模型的准确性和泛化能力. 下面分别介绍该方法的建模策略和实现过程.

2.1 建模策略

鲁棒加权异构特征集成建模方法的建模策略如图 2 所示. 首先, 依据焚烧过程机理和炉排结构,

将 MSW 焚烧过程炉温的高维特征变量训练集划分为异构特征集合, 并以互信息和相关系数综合评估每组异构特征对炉温的贡献度; 其次, 采用文献 [16] 的鲁棒 SCN 建模方法, 构建每组异构特征对应的基模型, 并综合所有基模型的训练情况, 确定训练样本的惩罚权重; 最后, 根据训练样本的惩罚权重和每组异构特征的贡献度, 设计一种鲁棒加权 NCL 策略, 实现基模型间的同步训练, 从而获得最终的炉温预测模型.

图 2 中, D 表示炉温的高维特征训练集, d 表示输入变量维度, N 表示训练样本数量; D_p 表示第 p 组异构特征对应的训练子集, d_p 表示第 p 组异构特征的维度, $p = 1, 2, \dots, 12$, 所有训练集的输出变量保持一致; \tilde{A}_p 表示第 p 组异构特征对炉温的贡献度, 由输入变量和输出变量的互信息和相关系数综合确定; e_p 表示第 p 个基模型的损失函数, Φ 是训练样本的惩罚权重, H_p 和 β_p 分别表示第 p 个基模型的隐含层输出矩阵和输出权重矩阵, H 和 β 分别由所有基模型隐含层输出矩阵和输出权重矩阵组成; μ 为 NCL 惩罚因子, Y 为相应的输出矩阵.

2.2 实现过程

基于上述建模策略, 本节分别介绍异构特征划分与贡献度评估、基模型训练和鲁棒加权同步训练的实现过程, 并在最后给出算法伪代码.

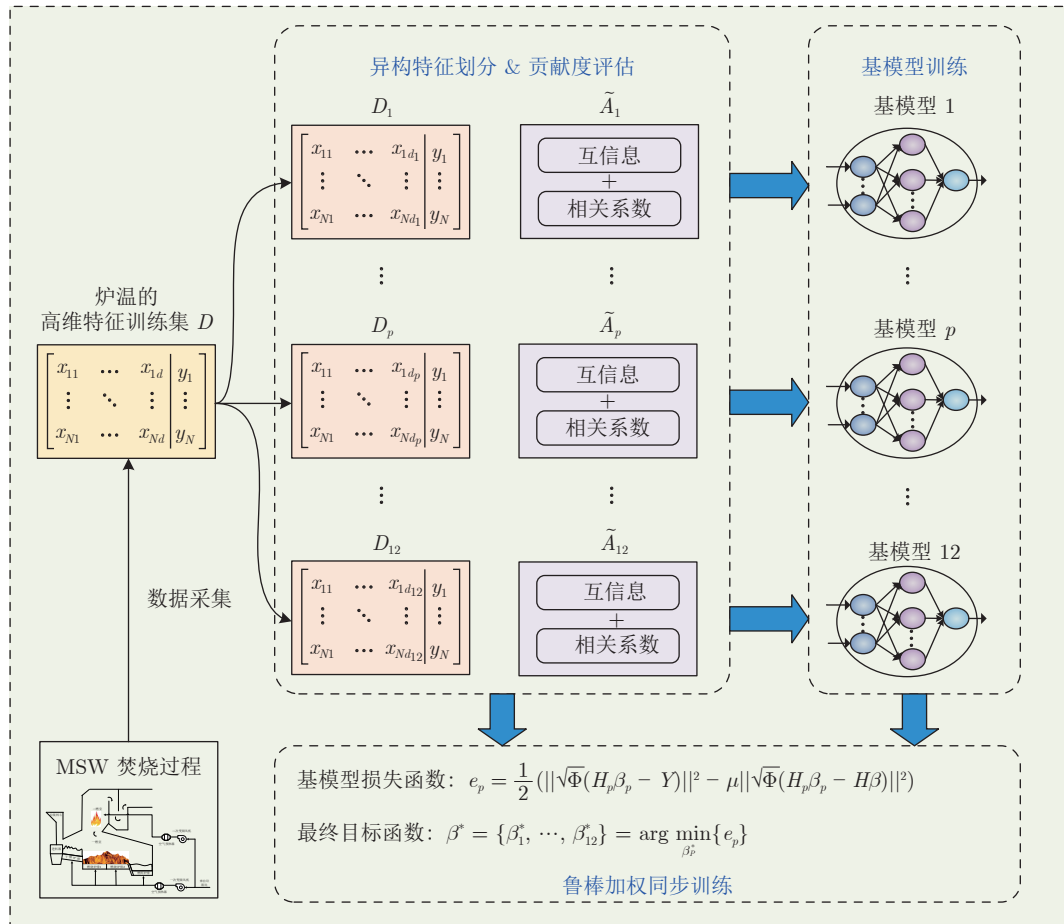


图 2 建模策略图

Fig.2 Diagram of the modeling strategy

2.2.1 异构特征划分与贡献度评估

从焚烧过程运行机理看, 炉温受水分干燥、挥发分析出、挥发分燃烧等阶段影响^[21-22]. 另外, 从炉排上方热电偶分布情况看, 炉排上方安装了 12 组 K 型铠装热电偶, 分布情况如图 3 所示. 综合考虑各阶段的运行机理和炉排上方热电偶分布, 将表 A1 中的特征变量划分为 12 组异构特征, 每组异构特征包括当前段的炉排速度、一次风量、炉排出口温度、一次风温度、一次风机压力、二次风量和当前炉温 7 个变量. 此时, 异构特征对应的训练集记为 $D_p = \{X_p, Y\}$, 其中 $p = 1, 2, \dots, 12$, X_p 为第 p 个训练集的输入矩阵.

首先, 对第 p 个训练集 D_p , 分别计算每个输入变量与炉温的互信息和相关系数:

$$I(x_i; Y) = \sum_{x \in x_i} \sum_{y \in Y} p(x, y) \log_2 \frac{p(x, y)}{p_x(x)p_y(y)} \quad (1)$$

$$\rho(x_i; Y) = \frac{\text{Cov}(x_i, Y)}{\sqrt{\text{Var}(x_i)\text{Var}(Y)}} \quad (2)$$




图 3 炉排上方热电偶分布情况

Fig.3 The distribution diagram of thermocouple on the grate

式中, $x_i \in \mathbf{R}^{1 \times N}$ 表示第 i 个输入变量, $Y \in \mathbf{R}^{1 \times N}$ 表示输出矩阵即炉温; $p_x(x)$ 和 $p_y(y)$ 分别表示 x 和 y 的边缘概率分布; $p(x, y)$ 表示 x 和 y 的联合概率分布; $i = 1, 2, \dots, d_p$, d_p 为第 p 组异构特征的特征数量, $p = 1, 2, \dots, 12$; $\text{Cov}(x_i, Y)$ 表示 x_i 与 Y 之间的协方差; $\text{Var}(x_i)$ 和 $\text{Var}(Y)$ 分别表示 x_i 与 Y 之间的方差. 然后, 采用互信息和相关系数的乘积作为每个特征变量与输出变量相关性的评估指标, 并以

所有变量与炉温相关性的平均值表示第 p 组异构特征的贡献度:

$$\begin{cases} a_i = I(x_i; Y)\rho(x_i; Y), & i = 1, 2, \dots, d_p \\ A_p = \frac{1}{d_p} \sum_{i=1}^{d_p} a_i \end{cases} \quad (3)$$

式中, a_i 表示第 i 个特征变量与炉温的相关性; A_p 表示第 p 组异构特征的贡献度, 故 A_p 越大, 表示该异构特征对炉温影响越大.

最后, 对每组异构特征的贡献度进行归一化处理:

$$\tilde{A}_p = \frac{A_p}{\sum_{p=1}^{12} A_p} \quad (4)$$

式中, \tilde{A}_p 表示归一化后, 第 p 组异构特征的贡献度.

2.2.2 基模型训练

焚烧过程数据中的异常值会降低基模型准确性, 因此, 本节采用基于混合 t 分布的鲁棒 SCN^[16], 实现基模型的训练过程. 该方法实现步骤如下:

步骤 1. 初始化基模型的最大隐含层神经元数量、最大随机配置次数和混合 t 分布的位置参数、尺度参数和自由度;

步骤 2. 采用 SC-III 算法, 确定基模型的网络结构和连接权重;

步骤 3. 计算基模型输出权重在给定训练集下的期望值;

步骤 4. 使步骤 3 中的期望值最大化, 从而确定模型输出权重和混合 t 分布的位置参数、尺度参数和自由度;

步骤 5. 判断算法是否收敛? 若达到收敛条件, 基模型训练结束; 否则, 返回步骤 3.

因此, 训练完成的基模型 M_p 可以表示为:

$$M_p = H_p \beta_p = \begin{bmatrix} \varphi_{p,1}(x_{p,1}) & \cdots & \varphi_{p,L_p}(x_{p,1}) \\ \vdots & \ddots & \vdots \\ \varphi_{p,1}(x_{p,N}) & \cdots & \varphi_{p,L_p}(x_{p,N}) \end{bmatrix} \begin{bmatrix} \beta_{p,1} \\ \vdots \\ \beta_{p,L_p} \end{bmatrix} \quad (5)$$

式中, H_p 和 β_p 分别表示第 p 个基模型的隐含层输出矩阵和输出权重矩阵; $\varphi(\cdot)$ 是 Sigmoid 激活函数; L_p 表示第 p 个基模型的隐含层神经元数量, $p = 1, 2, \dots, 12$. 为了后续表述简洁, 令 $H = [H_1, \dots, H_{12}]$ 表示由所有基模型隐含层输出和贡献度乘积构成的矩阵; $\beta = [\beta_1, \dots, \beta_{12}]$ 表示所有基模型输出权重构成的矩阵. 在上述训练过程中, 每个基模型均可获得一组训练样本的惩罚权重矩阵, 综合考虑所有基

模型的训练结果, 将所有惩罚权重矩阵的均值作为最终训练集的惩罚权重, 记为 Φ . 此时, 基模型训练过程结束.

注 1. 本节采用基于混合 t 分布的鲁棒 SCN^[16] 构建基模型, 其优势在于混合 t 分布具有重尾特性, 且通过调整自由度可以使其概率密度曲线适应不同类型的异常值分布, 故该方法构建的基模型对训练数据中的异常值具有较强的鲁棒性. 此外, 在基模型训练过程中, 可以获得训练样本的惩罚权重, 这为后续鲁棒加权同步训练奠定了基础.

2.2.3 鲁棒加权同步训练

NCL 策略是实现神经网络集成模型同步训练的重要方法, 该方法通过在神经网络集成的损失函数中, 引入基模型间的相关惩罚项, 实现基模型输出之间的负相关, 从而降低基模型输出之间的协方差^[20]. 文献 [19] 和文献 [23] 均采用了 NCL 策略, 实现了随机学习模型间的同步训练, 从而提升了神经网络集成模型的准确性. 然而, 在 MSW 焚烧过程中, 由于运行数据中存在服从未知分布的异常值, 导致 NCL 策略的鲁棒性难以保证. 因此, 本节设计一种鲁棒加权 NCL 策略, 来实现基模型之间的鲁棒同步训练.

在每个基模型的代价函数中引入训练样本的惩罚权重矩阵 Φ , 则第 p 个基模型的训练代价函数为:

$$e_p = \frac{1}{2} \left(\left\| \sqrt{\Phi} (H_p \beta_p - Y) \right\|^2 - \mu \left\| \sqrt{\Phi} (H_p \beta_p - H \beta) \right\|^2 \right) \quad (6)$$

式中, $p = 1, 2, \dots, 12$, H_p 和 β_p 分别表示第 p 个基模型的隐含层输出矩阵和输出权重矩阵, $H = [\tilde{A}_1 H_1, \dots, \tilde{A}_{12} H_{12}]$ 表示由所有基模型隐含层输出和贡献度乘积构成的矩阵, $\beta = [\beta_1, \dots, \beta_{12}]^T$ 表示所有基模型输出权重构成的矩阵, Y 表示输出矩阵, $\mu \in [0, 1]$ 表示惩罚因子.

此时, 鲁棒异构特征集成模型的目标函数可以表示为:

$$\beta^* = \{\beta_1^*, \dots, \beta_{12}^*\} = \arg \min_{\beta_p^*} \{e_p\} \quad (7)$$

式中, β^* 表示同步训练后集成模型的隐含层输出权重矩阵.

因此, 令 $\frac{\partial e_p}{\partial \beta_p} = 0$, 可得:

$$\begin{aligned} & \left(1 - \mu (\tilde{A}_p - 1) \right)^2 H_p^T \Phi H_p \beta_p + \\ & \mu (1 - \tilde{A}_p) H_p^T \Phi \tilde{H}_p \beta = H_p^T \Phi Y \end{aligned} \quad (8)$$

例的样本作为异常样本, 并将这些样本的输出进行异常化处理, 具体处理方式:

$$y_{i, outlier} = y_i + \text{sign}[\text{rand}(0, 1)(\max(y_i) - \min(y_i))] \quad (15)$$

式中, y_i 和 $y_{i, outlier}$ 分别表示炉温的真实值和处理后的异常值, $\text{rand}(0, 1)$ 表示 0 和 1 之间的随机数, $\max(y_i)$ 和 $\min(y_i)$ 分别表示正常工况下炉温的最大值和最小值. 为了使异常值分布更加不平衡, 正偏差异常值 ($\text{sign} = 1$) 和负偏差异常值 ($\text{sign} = -1$) 的比例设置为 2:1.

3.2 性能测试

本节对基于鲁棒加权异构特征集成的炉温预测模型开展性能测试. 为了后续表述简洁, 将本文方法命名为 Mt-RSCNE. 由图 4 的异构特征集合对炉温的互信息、相关系数和贡献度的对比可以看出, 第 1~4 组的贡献度较高, 说明干燥段炉排对应的特征变量对炉温变化的影响较大. 其原因在于 MSW 具有高水分、低热值的特点, 随着焚烧过程运行, 在水分干燥过程中吸收的热量差异较大. 因此, 结果与焚烧过程的运行机理存在一致性.

基模型隐含层神经元数量 L_{max} 和 NCL 惩罚因子 μ 是 Mt-RSCNE 模型中的两个重要参数. 为了验证模型对上述超参数的鲁棒性, 图 5 和图 6 分别为 L_{max} 和 μ 取不同数值时, 模型测试误差的分布情况. 其中, L_{max} 的取值为 10~50, 间隔数量为 5; μ 的取值为 0.1~0.9, 间隔数量为 0.1. 由图 5 可以看出, 随着基模型隐含层神经元数量的增加, 炉温预测模型 50 次实验的测试误差均值变化较小, 但测试误差的标准差变化较大, 说明当 L_{max} 较大时, 炉温预测模型可能出现过拟合现象. 因此, 在后续实验中, 基模型隐含层神经元数量设置为 15. 由图 6 可以看出, μ 的取值对炉温预测模型的测试性能有轻微影响, 但影响并不显著, 说明本文方法对参数 μ 具有较好的鲁棒性.

3.3 对比分析

为了验证本文提出的 Mt-RSCNE 模型在准确性和泛化能力方面的优越性, 本节将该方法与典型建模方法构建的炉温预测模型的预测结果进行对比分析. 为表达简洁, 使用如下缩写表示各建模方法: MoGL-SCNE 表示基于混合高斯分布和拉普拉斯分布的集成 SCN 建模方法^[15], SCNE 表示基于 SCN 的经典异构特征集成方法^[19], DNNE 表示快速去相关神经网络集成方法^[23], BESCEN 表示基于 Bootstrap 集成的 SCN^[24].

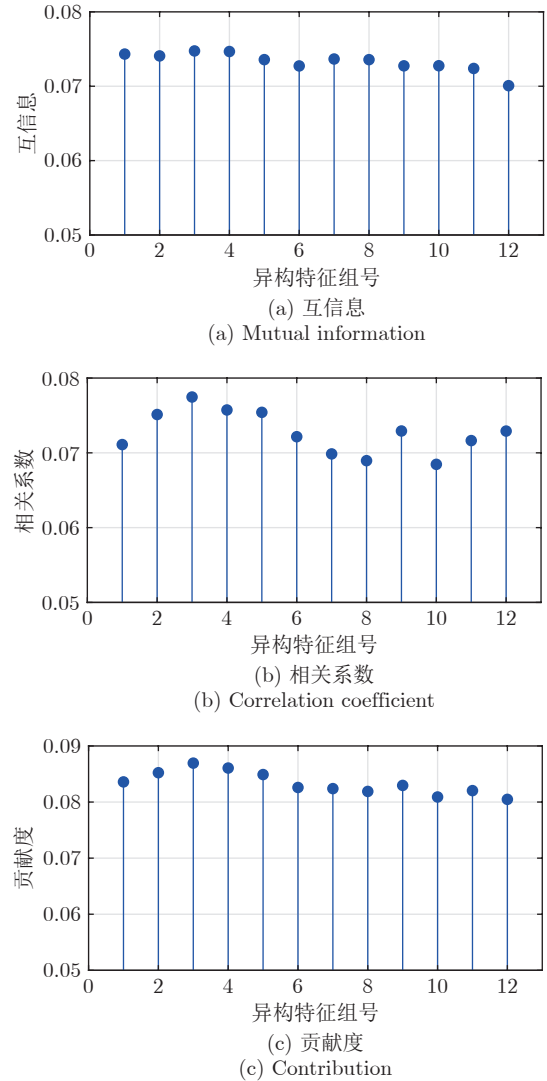


图 4 每组异构特征集合对炉温的互信息、相关系数和贡献度对比

Fig. 4 Comparison of mutual information, correlation coefficient, and contribution of each heterogeneous feature set to furnace temperature

本文的 Mt-RSCNE 方法的实验参数设置如下: 基模型隐含层神经元数量为 15, 基模型最大配置次数为 50, 混合 t 分布的组分数量为 3, 权重分别为 0.5、0.3 和 0.2, 位置参数均为 0, 尺度参数分别为 0.12、0.11 和 0.10, 自由度均为 4, NCL 惩罚因子 μ 为 0.1. 对比方法参数设置如下: 1) DNNE 方法. 基模型数量为 12, 基模型隐含层神经元数量为 15, 随机权重选择范围为 $[-1, 1]$. 2) SCNE 方法. 与本文方法一致. 3) MoGL-SCNE 方法. 基模型数量为 12, 基模型隐含层神经元数量为 15, 混合分布由高斯分布和两个拉普拉斯分布组成. 其中高斯分布的权重为 0.8, 均值为 0, 方差为 0.2, 两个拉普拉斯分布权重均为 0.1, 尺度参数均为 0.1. 4) BESCEN 方

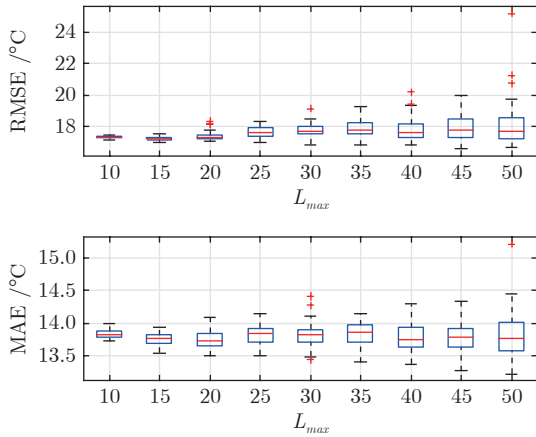


图 5 L_{max} 取值为 10 ~ 50 时, 炉温预测模型在验证集上的误差分布

Fig.5 Error distribution of the furnace temperature prediction model on the verification set with L_{max} from 10 ~ 50

法. 基模型数量为 12, 基模型隐含层神经元数量为 15, 误差分布和输出权重先验分布的方差分别为 1 和 0.5. 上述实验参数均采用验证集测试获得.

在训练数据输出中, 分别引入 0%、10% 和 20% 比例的异常值时, 上述 5 种建模方法构建的炉温预测模型的 RMSE 和 MAE 分布如图 7 所示. 由图 7






图 6 μ 取值为 0.1 ~ 0.9 时, 炉温预测模型在验证集上的误差分布

Fig.6 Error distribution of the furnace temperature prediction model on the verification set with μ from 0.1 ~ 0.9

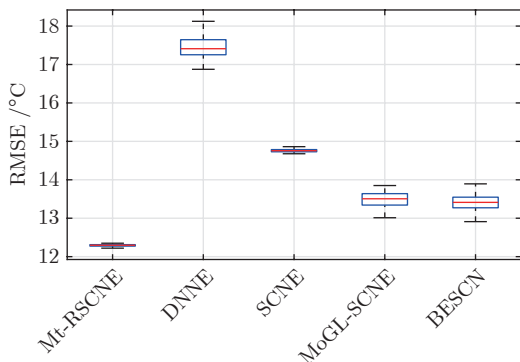
可以看出, 采用异构特征集成框架的炉温预测模型 (Mt-RSCNE 和 SCNE) 的测试误差明显低于其他方法, 这说明异构特征集成可以缓解高维特征变量对模型准确性和泛化能力的影响. 当训练集引入 10% 和 20% 的异常值时, 本文提出的 Mt-RSCNE 的测试误差变化幅度较小, 说明本文设计的鲁棒加权 NCL




(a) 未额外引入异常值时的测试 RMSE
(a) Test RMSE without introducing additional outlier



(b) 未额外引入异常值时的测试 MAE
(b) Test MAE without introducing additional outlier



(c) 额外引入 10% 异常值时的测试 RMSE
(c) Test RMSE with an additional 10% outlier



(d) 额外引入 10% 异常值时的测试 MAE
(d) Test MAE with an additional 10% outlier

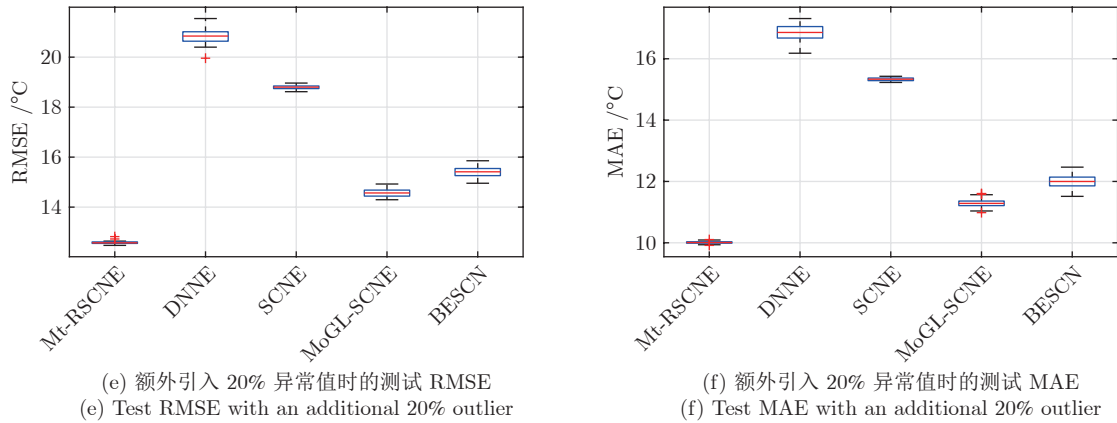


图 7 在不同异常值比例下, 各集成模型对炉温预测的性能对比

Fig.7 Performance comparison of ensemble models for furnace temperature prediction under different percentages of abnormal value

策略可以提升炉温预测模型对异常数据的鲁棒性. 表 1 和表 2 为上述对比结果的具体数值.

为了更直观地表现本文 Mt-RSCNE 方法对训练数据中异常值的鲁棒性, 图 8 绘制了上述 5 种集成炉温预测模型在 20% 的异常值情况下的散点图. 由图 8 可以看出, Mt-RSCNE 方法对对应点的位置更加靠近对角线, 说明该方法得到炉温预测模型的结果更接近真实值. 再次验证了本文方法在炉温预测准确性和泛化能力方面的优越性, 同时也说明了本文方法在工业过程参数建模领域中, 具有一定的应用价值.

4 结束语

为了提升 MSW 焚烧过程炉温预测模型的准确性和泛化能力, 本文提出一种鲁棒加权异构特征集成建模方法, 并采用焚烧过程历史运行数据验证了

该方法的有效性. 本文的主要贡献如下:

- 1) 针对焚烧过程数据具有高维特征变量的特点, 依据 MSW 焚烧过程的机理和炉排结构, 将高维特征划分为异构特征集合, 并采用互信息与相关系数, 综合确定每组异构特征对炉温的贡献度;
- 2) 针对焚烧过程数据具有异常值的特点, 采用基于混合 t 分布的鲁棒 SCN 构建基模型, 并综合基模型的训练过程确定样本惩罚权重, 从而保证了基模型对数据中异常值的鲁棒性;
- 3) 设计一种鲁棒加权 NCL 策略, 实现了基模型之间的鲁棒同步训练, 从而提升了炉温预测模型的准确性和泛化能力.

实验结果表明, 与典型集成建模方法相比, 本文构建的 MSW 焚烧过程炉温预测模型在准确性和泛化能力方面具有优势, 说明该方法在工业过程参数建模领域具有应用价值. 值得注意的是, 该方法

表 1 在不同异常值比例下, 各集成炉温预测模型的测试 RMSE (均值 \pm 标准差) ($^{\circ}\text{C}$)
Table 1 Test RMSE of each ensemble furnace temperature prediction model under different percentages of abnormal value (mean \pm standard deviation) ($^{\circ}\text{C}$)

异常值比例 (%)	Mt-RSCNE	DNNE	SCNE	MoGL-SCNE	BESCIN
0	16.3 \pm 0.06	18.0 \pm 0.24	16.4 \pm 0.06	17.1 \pm 0.12	17.1 \pm 0.13
10	16.6 \pm 0.06	18.1 \pm 0.23	16.9 \pm 0.11	17.2 \pm 0.14	17.2 \pm 0.20
20	16.6 \pm 0.06	19.6 \pm 0.26	18.0 \pm 0.10	18.6 \pm 0.12	17.9 \pm 0.22

表 2 在不同异常值比例下, 各集成炉温预测模型的测试 MAE (均值 \pm 标准差) ($^{\circ}\text{C}$)
Table 2 Test MAE of each ensemble furnace temperature prediction model under different percentages of abnormal value (mean \pm standard deviation) ($^{\circ}\text{C}$)

异常值比例 (%)	Mt-RSCNE	DNNE	SCNE	MoGL-SCNE	BESCIN
0	12.9 \pm 0.06	14.4 \pm 0.23	13.0 \pm 0.07	13.8 \pm 0.12	13.8 \pm 0.13
10	13.1 \pm 0.06	14.3 \pm 0.22	13.3 \pm 0.10	13.5 \pm 0.12	13.7 \pm 0.15
20	13.1 \pm 0.05	15.6 \pm 0.21	14.4 \pm 0.09	15.3 \pm 0.13	14.6 \pm 0.19




图 8 在 20% 异常值情况下, 各集成模型输出的散点图
Fig.8 Scatter diagram of the output of each ensemble model under 20% abnormal value

的训练模式为离线批量训练, 这导致模型的训练效率会随训练样本数量的增加而降低. 因此, 针对提升模型训练效率或模型在线自适应学习能力的研究, 是未来研究的主要方向.

附录 A

表 A1 炉温预测模型过程变量明细
Table A1 Process variable details of furnace temperature prediction model

序号	名称	单位
1	干燥炉排左内侧速度	%
2	干燥炉排左外侧速度	%
3	干燥炉排右内侧速度	%
4	干燥炉排右外侧速度	%
5	燃烧炉排 1 左内侧速度	%
6	燃烧炉排 1 左外侧速度	%
7	燃烧炉排 1 右内侧速度	%
8	燃烧炉排 1 右外侧速度	%
9	燃烧炉排 2 左内侧速度	%
10	燃烧炉排 2 左外侧速度	%
11	燃烧炉排 2 右内侧速度	%
12	燃烧炉排 2 右外侧速度	%
13	干燥炉排左 1 空气流量	km ³ N/h
14	干燥炉排右 1 空气流量	km ³ N/h
15	干燥炉排左 2 空气流量	km ³ N/h
16	干燥炉排右 2 空气流量	km ³ N/h
17	燃烧段炉排左 1-1 段空气流量	km ³ N/h
18	燃烧段炉排右 1-1 段空气流量	km ³ N/h
19	燃烧段炉排左 1-2 段空气流量	km ³ N/h
20	燃烧段炉排右 1-2 段空气流量	km ³ N/h
21	燃烧段炉排左 2-1 段空气流量	km ³ N/h
22	燃烧段炉排右 2-1 段空气流量	km ³ N/h

表 A1 炉温预测模型过程变量明细 (续表)

Table A1 Process variable details of furnace temperature prediction model (continued table)

序号	名称	单位
23	燃烧段炉排左 2-2 段空气流量	km ³ N/h
24	燃烧段炉排右 2-2 段空气流量	km ³ N/h
25	二次风流量	km ³ N/h
26	一次风机出口空气压力	kPa
27	干燥段炉排左内侧温度	°C
28	干燥段炉排左外侧温度	°C
29	干燥段炉排右内侧温度	°C
30	干燥段炉排右外侧温度	°C
31	燃烧段炉排 1 左内侧温度	°C
32	燃烧段炉排 1 左外侧温度	°C
33	燃烧段炉排 1 右内侧温度	°C
34	燃烧段炉排 1 右外侧温度	°C
35	燃烧段炉排 2 左内侧温度	°C
36	燃烧段炉排 2 左外侧温度	°C
37	燃烧段炉排 2 右内侧温度	°C
38	燃烧段炉排 2 右外侧温度	°C
39	干燥段炉排进口空气温度	°C
40	燃烧段炉排进口空气温度	°C
41	一次风加热器出口空气温度	°C
42	炉温 (当前值)	°C
43	炉温 (预测值)	°C

References

- Zhao X G, Jiang G W, Li A, Li Y. Technology, cost, a performance of waste-to-energy incineration industry in China. *Renewable and Sustainable Energy Reviews*, 2016, **55**(3): 115-130
- Cheng H F, Hu Y A. Municipal solid waste (MSW) as a renewable source of energy: Current and future practices in China. *Bioresource Technology*, 2010, **101**(11): 3816-3824
- Nzihou A, Themelis N J, Kemihla M, Benhamou Y. Dioxin emissions from municipal solid waste incinerators (MSWIs) in France. *Waste Management*, 2012, **32**(12): 2273-2277
- Ding H X, Tang J, Qiao J F. Dynamic modeling of multi-input and multi-output controlled object for municipal solid waste incineration process. *Applied Energy*, 2023, **339**(1): Article No. 120982
- Alobaid F, Al-Maliki W A K, Lanz T, Haaf M, Brachthausen A, Epple B, et al. Dynamic simulation of a municipal solid waste incinerator. *Energy*, 2018, **149**(4): 230-249
- He H J, Meng X, Tang J, Qiao J F. A novel self-organizing TS fuzzy neural network for furnace temperature prediction in MSWI process. *Neural Computing and Applications*, 2022, **34**(12): 9759-9776
- Ding Hai-Xu, Tang Jian, Xia Heng, Qiao Jun-Fei. Modeling of MIMO controlled object in municipal solid waste incineration process based on TS-FNN. *Control Theory & Applications*, 2022, **39**(8): 1529-1540
(丁海旭, 汤健, 夏恒, 乔俊飞. 基于 TS-FNN 的城市固体废物焚烧过程 MIMO 被控对象建模. *控制理论与应用*, 2022, **39**(8): 1529-1540)
- Scardapane S, Wang D H. Randomness in neural networks: An overview. *Wiley Interdisciplinary Reviews: Data Mining and*

- Knowledge Discovery*, 2017, **7**(2): 1–18
- 9 Wang D H, Li M. Stochastic configuration networks: Fundamentals and algorithms. *IEEE Transactions on Cybernetics*, 2017, **47**(10): 3346–3479
 - 10 Lu J, Ding J L. A novel stochastic configuration network with iterative learning using privileged information and its application. *Information Sciences*, 2022, **613**(10): 953–965
 - 11 Wang Q, Hong Q, Wu S, Dai W. Multi-target stochastic configuration network and applications. *IEEE Transactions on Artificial Intelligence*, 2023, **4**(2): 338–348
 - 12 Dai Wei, Li De-Peng, Yang Chun-Yu, Ma Xiao-Ping. A model and data hybrid parallel learning method for stochastic configuration networks. *Acta Automatica Sinica*, 2021, **47**(10): 2427–2437
(代伟, 李德鹏, 杨春雨, 马小平. 一种随机配置网络的模型与数据混合并行学习方法. *自动化学报*, 2021, **47**(10): 2427–2437)
 - 13 Wang D H, Li M. Robust stochastic configuration networks with kernel density estimation for uncertain data regression. *Information Sciences*, 2017, **412**(10): 210–222
 - 14 Li M, Huang C Q, Wang D H. Robust stochastic configuration networks with maximum corr-entropy criterion for uncertain data regression. *Information Sciences*, 2019, **473**(4): 73–86
 - 15 Lu J, Ding J L. Mixed-distribution based robust stochastic configuration networks for prediction interval construction. *IEEE Transactions on Industrial Informatics*, 2020, **16**(8): 5099–5109
 - 16 Yan A J, Guo J C, Wang D H. Robust stochastic configuration networks based on Student's-*t* mixture distribution. *Information Sciences*, 2022, **607**(8): 493–505
 - 17 Zaman E A K, Mohamed A, Ahmad A. Feature selection for online streaming high-dimensional data: A state-of-the-art review. *Applied Soft Computing*, 2022, **127**(9): Article No. 109355
 - 18 Chandrashekar G, Sahin F. A survey on feature selection methods. *Computers and Electrical Engineering*, 2014, **40**(12): 16–28
 - 19 Wang D H, Cui C H. Stochastic configuration networks ensemble with heterogeneous features for large-scale data analytics. *Information Sciences*, 2017, **417**(31): 55–71
 - 20 Liu Y, Yao X. Simultaneous training of negatively correlated neural networks in an ensemble. *IEEE Transactions on Systems, Man, and Cybernetics — Part B: Cybernetics*, 1999, **29**(6): 716–725
 - 21 Zhuang J B, Tang J, Aljerf L. Comprehensive review on mechanism analysis and numerical simulation of municipal solid waste incineration process based on mechanical grate. *Fuel*, 2022, **320**(4): 1–20
 - 22 Xia Z, Shan P, Chen C, Du H, Huang J, Bai L. A two-fluid model simulation of an industrial moving grate waste incinerator. *Waste Management*, 2020, **104**(1): 183–191
 - 23 Alhamdoosh M, Wang D H. Fast decor-related neural network

ensembles with random weight. *Information Sciences*, 2014, **264**(11): 104–117

- 24 Lu J, Ding J L, Dai X, Chai T Y. Ensemble stochastic configuration networks for estimating prediction intervals: A simultaneous robust training algorithm and its application. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, **31**(12): 5426–5440



郭京承 北京工业大学信息学部博士研究生. 主要研究方向为复杂过程建模, 智能优化控制方法.

E-mail: guojingcheng@ncut.edu.cn

(**GUO Jing-Cheng** Ph.D. candidate at the Faculty of Information Technology, Beijing University of Technology. His research interest covers complex process modeling and intelligent optimization control method.)



严爱军 北京工业大学信息学部教授. 主要研究方向为复杂过程建模, 智能优化控制方法. 本文通信作者.

E-mail: yanaijun@bjut.edu.cn

(**YAN Ai-Jun** Professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers complex process modeling and intelligent optimization control method. Corresponding author of this paper.)



汤健 北京工业大学信息学部教授. 主要研究方向为小样本数据建模, 城市固体废物处理过程智能控制.

E-mail: freeflytang@bjut.edu.cn

(**TANG Jian** Professor at the Faculty of Information Technology, Beijing University of Technology. His research interest covers small sample data modeling and intelligent control of municipal solid waste treatment process.)