

基于生成对抗网络的入炉垃圾热值预测研究

赵 征, 钟尚峰, 任远卓, 王浩杰

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

摘要: 垃圾焚烧是城市生活垃圾处理的主要方式, 而垃圾热值对焚烧炉的改造设计及其燃烧状况调整有指导性意义。为准确预测垃圾热值, 提出一种基于生成对抗网络的垃圾热值预测模型。首先利用垃圾焚烧炉内热平衡原理计算得到垃圾热值真值, 然后分析垃圾热值影响因素并确定输入生成对抗网络的主要特征变量, 经生成器与判别器的对抗训练后最终生成与真实数据特征相似的模拟数据; 验证模拟数据的可靠性后将其与原始数据共同组成扩充数据集并输入最小二乘支持向量机模型进行训练与测试。实验表明, 利用生成的模拟数据扩充数据集后, 垃圾热值的预测准确率得到提高, 且预测精度优于其他预测模型。

关键词: 垃圾热值; 生成对抗网络; 预测模型; 最小二乘支持向量机

中图分类号: TK12 **文献标志码:** A **文章编号:** 1007-2691 (2026) 02-0150-09

Research on Calorific Value Prediction of Incoming Waste Based on Generative Adversarial Network

ZHAO Zheng, ZHONG Shangfeng, REN Yuanzhuo, WANG Haojie

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Waste incineration serves as the primary method for urban solid waste treatment, where the waste calorific value provides critical guidance for incinerator retrofitting design and combustion condition adjustment. In order to accurately predict the waste calorific value, a calorific value prediction model based on a generative adversarial network is proposed. Firstly, the true value of waste calorific value is calculated by using the heat balance principle in the waste incinerator. Then, the influencing factors of waste calorific value are analyzed and the main feature variables for the input of the generative adversarial network are determined. After the adversarial training of the generator and the discriminator, simulation data similar to the characteristics of the real data is generated. After verifying the reliability of the simulation data, it is combined with the original data to form an enriched dataset and inputted into the least squares support vector machine model for training and testing. Experiment results show that after enriching the dataset with the generated simulation data, the prediction accuracy of the waste calorific value is improved, and the prediction performance is better than that of other prediction models.

Key words: waste calorific value; generative adversarial network; prediction model; least squares support vector machine

0 引言

相比传统的填埋方式, 垃圾焚烧已逐步成为城市生活垃圾的主要处理方式。我国生活垃圾具有多形态、水分多、挥发分高以及发热量低与固定

碳低的特性, 导致垃圾热值产生较大波动。而垃圾热值是城市生活垃圾能否进行焚烧发电利用的决定性指标, 其不仅为运行人员对垃圾焚烧处理决策提供理论支持, 也对焚烧炉的设计改造与炉内燃烧状况的调整有关键作用^[1]。然而, 目前垃圾焚烧发电厂缺少热值实时测点, 难以及时得到垃圾热值的真实值。因此, 如何准确预测入炉垃圾热值, 对垃圾焚烧发电厂的高效及安全运行具有重要意义。

对于入炉垃圾热值预测,国内外许多学者都进行了相关研究,他们通常用各个地区公开的垃圾热值数据集或对样本进行组分分析后根据公式计算垃圾热值,根据垃圾热值与预测结果的偏差调整模型。徐凯等^[2]根据能量平衡原理计算出入炉垃圾热值并由此构建垃圾热值不确定度计算模型。

然而,由以上方法计算得到的入炉垃圾热值具有滞后性,不能及时指导焚烧炉内燃烧状况的调整,为提前预测垃圾热值,需建立垃圾热值及其影响因素的预测模型。马晓茜等^[3,4]利用简单的反向传播网络、径向基神经网络与自适应神经模糊推理系统预测垃圾热值,实现垃圾热值较为准确的控制。Atul等^[5,6]基于不同的分析程度与特征变量建立多元回归模型预测垃圾热值,但上述回归模型只能用于特征相似的垃圾焚烧电厂,适用性较窄。谢昊源等^[7]通过构建垃圾图像数据集与改进 Yolov5 模型,使模型可识别不同类别垃圾并通过其占比预测该图像对应的垃圾热值。丁晨曦等^[8,9]将粒子群算法引入垃圾热值预测模型中,可训练得到有较好准确率与实时性的垃圾热值预测模型。杜星宇等^[10]提出建立广义回归神经网络 (Generalized Regression Neural Network, GRNN) 对垃圾热值进行预测,与传统经验公式对比可发现 GRNN 可有效规避经验公式适用性较差的问题。Wang 等^[11]比较了多元线性回归分析与基于人工神经网络 (Artificial Neural Network, ANN) 技术的模型,发现基于多元线性回归的垃圾热值预测方法对于不同特征生活垃圾的通用性较弱。

基于 ANN 的建模预测方法鲁棒性更强,但需要大量各工况下的历史数据训练模型。而最小二乘支持向量机^[12]对于垃圾热值此类非线性对象有较好的预测效果与较强的鲁棒性,是适合对垃圾热值进行预测的模型。生成对抗网络强大的特征抓取能力,已有学者将其应用于医疗、故障诊断与矿藏等领域的数据生成^[13-15],且其在电力领域中风电爬坡数据生成的准确性也得到验证^[16],因此可将其应用于垃圾热值数据集的扩充以加大建模数据量。

对此,本文提出一种基于垃圾热值影响因素分析与生成对抗网络的入炉垃圾热值预测方法。首先,由于垃圾焚烧发电厂缺少热值测点,需通过焚烧炉的热平衡模型反推出入炉垃圾热值作为其

历史真实数据与输入生成对抗网络的原始数据。其次,根据分析得到垃圾热值的主要影响因素为降雨量、相对湿度、季节与是否为节假日,对特征进行降维分类为后续建模作准备。再次,因历史数据较少,由其训练得到的模型预测效果不佳,将分类后的热值真实数据输入生成对抗网络,经迭代训练后得到生成数据。最后,将生成数据与真实数据作为最小二乘支持向量机的输入,得到垃圾热值预测结果。以某垃圾发电厂计算得到的垃圾热值历史数据集作仿真,验证了所提方案的可行性。另外,通过对比,可知生成数据与真实数据特征相似且均值处于相近水平,表明生成对抗网络可以解决垃圾热值真值数据缺少的问题,丰富数据集样本,并用于垃圾热值的预测建模。

1 基于热平衡的垃圾热值计算

垃圾的发热量有高位热值与低位热值两种,其区别在于燃烧产物中水的形态,水呈液态时是高位热值,水呈气态时是低位热值。垃圾焚烧炉内的工作温度为 800~1100℃,在此高温下垃圾燃烧所产生的水均以气态形式存在,故本文所提到的垃圾热值均为垃圾低位热值,其计算公式为

$$LHV = \frac{Q_{\text{waste}}}{m_{\text{waste}}} \quad (1)$$

式中: Q_{waste} 为当天入炉垃圾完全燃烧释放的热量, kJ; m_{waste} 为当天垃圾焚烧量, kg, 由干燥段料层厚度计算得到。垃圾蕴含热量 Q_{waste} 由焚烧炉热平衡关系得到

$$Q_{\text{waste}} = Q_{\text{out}} - Q_{\text{wind}} - Q_{\text{aux}} \quad (2)$$

式中: Q_{out} 为输出总热量, kJ; Q_{wind} 为加热空气后送风带入炉内的热量, kJ; Q_{aux} 为辅助燃料完全燃烧释放的热量, kJ。

由于散热损失、固体未完全燃烧热损失以及炉渣物理热损失均无法直接计算,由经验公式获取热损失百分比,总输出热量 Q_{out} 由式(3)计算:

$$Q_{\text{out}} = \frac{Q_1 + Q_2 + Q_3}{1 - q_4 - q_5 - q_6} \quad (3)$$

式中: Q_1 为炉内蒸汽升温所吸收的热量, kJ; Q_2 为排烟热损失, kJ; Q_3 为可燃气体未完全燃烧热损失, kJ; q_4 为固体未完全燃烧热损失, %; q_5 为散热损失, %; q_6 为灰渣物理热损失, %。

2 垃圾热值影响因素分析

运到垃圾发电厂的垃圾经过一定时间的发酵

后才可投入焚烧炉中,因此需将输入变量与计算得到的垃圾热值对应,例如某垃圾发电厂的垃圾发酵时间为 4 天,则 1 月 1 日的输入变量特征对应计算得到 1 月 5 日的垃圾热值。

垃圾热值主要由垃圾组分及其含水率决定,垃圾中 C、H 元素含量较多时,垃圾热值较高^[17];且生活垃圾含水率与热值呈负相关关系^[18]。我国南方省份垃圾热值明显高于北方省份,且东部沿海经济发达省份热值比内陆地区高^[17],其原因是北方省份垃圾灰分高,有机物含量相对减少;而经济发达地区垃圾中有机物含量高于欠发达地区。对于同一垃圾发电厂,影响这两个因素的外部变量主要是天气、季节性以及社会行为因素。天气与季节对含水率的影响体现在:降雨量与相对湿度增加,垃圾含水率相应增加;社会行为因素主要表现为:节假日人们的生活习惯改变以及消费水平提高,垃圾量及其中的有机物含量均增加,垃圾热值提高^[19]。因此得到垃圾热值的 5 个主要影响因素:降雨量、相对湿度、季节、气温及是否为节假日。

使用第 1 章中模型计算得到日均垃圾热值,对深圳某垃圾发电厂的历史数据进行分析,以 1、2、3、4 分别代表四个季节春、夏、秋、冬,并以 1、0 分别代表是否为节假日,得到编码不同的八类数据组成原始数据集,数据具有 4 维特征,分别为降雨量、相对湿度、气温与垃圾热值,每类数据的各项特征均值如表 1 所示,由表中内容可得:总体上春秋季节垃圾热值较高,冬季次之,夏季最低,其原因是深圳夏季多雨导致垃圾含水量较高,垃圾燃烧时水分蒸发消耗部分热量,使得垃圾热值降低。另外,节假日垃圾热值均比非节假日高 450 kJ/kg 左右。

表 1 每类数据均值

Tab. 1 Mean for each type of data

	降雨量/mm	相对湿度/%	气温/℃	热值/(kJ/kg)
春季非节假日	0.59	64.34	22.45	8 488.06
春季节假日	0.43	65.64	21.04	8 988.99
夏季非节假日	8.00	67.10	29.95	7 593.85
夏季节假日	11.01	67.07	28.97	7 957.12
秋季非节假日	5.51	61.59	23.28	8 650.55
秋季节假日	3.28	60.94	23.75	9 092.14
冬季非节假日	0.26	56.64	16.92	8 065.40
冬季节假日	0.13	54.76	17.23	8 528.47

对所建立的基于热平衡的垃圾热值计算模型,对季节与是否为节假日两个因素分别进行分析。为具体说明不同分类下数据特征的差异性,将原始数据标准化后用主成分分析(Principal

Component Analysis, PCA)对特征进行降维,取前 3 个主成分分量作为其特征^[20]。如图 1 所示,不同季节非节假日数据的特征分布集中在不同区域,表明不同季节对垃圾热值的影响有所区别。




图 1 不同季节非节假日数据特征对比图

Fig. 1 Comparison chart of non-holiday data characteristics in different seasons

不同季节的节假日与非节假日数据的特征分布如图 2 所示,由数据分布可得:每个季节节假日与非节假日数据的特征分布存在明显差异,说明节假日对垃圾热值的影响明显。其中秋冬季节节假日与非节假日的数据分布差异较大,原因是秋季有较长的国庆假期,人们的消费水平提高,垃圾中有机物明显增加,垃圾热值随之提高,使节假日数据特征产生较大改变。

3 基于 GAN-LSSVM 的垃圾热值预测

3.1 生成对抗网络

生成对抗网络(Generative Adversarial Network, GAN)由 Goodfellow 在 2014 年提出^[21],它由生成器 G 与判别器 D 两部分组成,且生成器与判别器均为神经网络模型。生成对抗网络的基本思想是通过生成器与判别器的博弈不断提高生成器的生成能力与判别器的判别能力,最终达到纳什均衡,此时判别器无法判断输入样本的真伪,表明生成器已学习到真实样本的数据特征及分布。使用二元交叉熵作为生成对抗网络模型的损失函数,判别器 D 的损失函数 $J^{(D)}$ 计算表达式如下:

$$J^{(D)} = - (1 - y) \lg \{ 1 - D[G(z)] \} - y \lg D(x) \tag{4}$$

生成器 G 的损失函数 $J^{(G)}$ 计算表达式如下:

$$J^{(G)} = (1 - y) \lg \{ 1 - D[G(z)] \} \tag{5}$$

式中: y 为样本标签; x 为真实样本; z 为生成器的




图2 各个季节节假日与非节假日数据特征对比

Fig. 2 Comparison of holiday and non-holiday data characteristics by season

输入,是随机高斯噪声; $G(z)$ 为生成器生成的伪样本; $D[G(z)]$ 与 $D(x)$ 分别判别器为对应伪样本与真实样本的输出,值为0或1。

生成对抗网络通过交替训练优化生成器与判别器的参数,最终判别器无法对生成器生成伪样本的真实性进行判别,即 $D[G(z)] = 0.5$,使得目标函数最小化:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}} \lg D(x) + E_{z \sim P_z} \lg D\{1 - D[G(z)]\} \quad (6)$$

式中: $E_{x \sim P_{\text{data}}}$ 为 x 的熵; P_{data} 为 x 的概率分布; $E_{z \sim P_z}$ 为 z 的熵; P_z 为 z 的概率分布。

生成对抗网络结构如图3所示。




图3 生成对抗网络结构

Fig. 3 Structure of generative adversarial network

3.2 最小二乘支持向量机模型

最小二乘支持向量机 (Least Squares Support Vector Machine, LS-SVM) 是一种支持向量机 (Support Vector Machine, SVM) 的变体,该模型的具体思想为:

给定训练集 $Q = \{(x_i, y_i) \mid i = 1, 2, \dots, N\}$, 其中 x_i 为 n 维输入向量, y_i 为输出向量, N 为训练样本总数,以误差 e 的平方和作为损失函数,并采用等式约束取代 SVM 中的不等式约束,由此 LS-SVM 的优化问题可表示为

$$\min_{w, s, e} J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \lambda \sum_{i=1}^N e_i^2 \quad (7)$$

s. t. $y_i = w^T \cdot \varphi(x_i) + s + e_i$

式中: w 为权值变量; λ 为正正则化参数,用于平衡模型复杂度最小和精度最高; s 为阈值; e_i 为误差值; $\varphi(\cdot)$ 为核空间内一个非线性映射。根据拉格朗日乘数法将原问题转化为乘子 $\alpha_i (\alpha_i \geq 0)$ 求极大值的问题,构造如下函数:

$$L(w, s, e, \alpha) = J(w, e) - \sum_{i=1}^N \alpha_i (w^T \varphi(x_i) + s + e_i - y_i) \quad (8)$$

根据 KKT (Karush-Kuhn-Tucker) 优化条件求得最优解,则 LS-SVM 的回归函数为

$$f(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + s \quad (9)$$

式中: x 为训练集中的输入向量; α_i, s 为式(8)的求解结果; $K(x, x_i)$ 为核函数,选择结构简单且稳健性强的径向基函数作为核函数,其表达式为

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|}{2\sigma^2}\right) \quad (10)$$

式中: σ^2 为核函数宽度,根据式(9)对垃圾热值进行预测。

相比传统 SVM,LS-SVM 不仅提高了求解速度,还提升了收敛精度,具有更高的计算效率,更强的鲁棒性与解释性。

3.3 基于 GAN-LSSVM 的垃圾热值预测

垃圾热值预测步骤如下:首先,由分析得出当地垃圾热值主要有 5 个影响因素,分别为:降雨量、相对湿度、气温、季节与是否为节假日,将其作为数据的五个特征。其次,将原始数据按四个季

节与是否为节假日一共分为 8 类,每类数据分别输入 GAN 中进行对抗训练,训练完成后生成与原始数据特征相似的八类模拟数据。再次,把原始数据与 GAN 生成的模拟数据混合以组成扩充后数据集,并输入 LS-SVM 模型中训练,得到训练好的垃圾热值预测模型。最后,分别将未加入扩充后数据集的原始数据的 5 个特征输入模型中进行垃圾热值预测,模型结构如图 4 所示。




图 4 预测模型结构图

Fig. 4 Prediction model structure diagram

4 实例验证与分析

为消除各参数数据之间量纲不同对计算的影响并提高模型收敛速度,对数据进行标准化处理:

$$x^* = \frac{x - \bar{x}}{\sigma}$$
 (11)

式中: x 为某参数原始数据; x^* 为标准化后的数据; $\bar{x}$ 为原始数据的均值; σ 为该参数原始数据的标准差。

4.1 生成数据相似性验证

为验证 GAN 生成数据的可靠性,将八类生成数据用 PCA 降维后提取 3 个主要分量,分别与原始数据进行对比,如图 5 与图 6 所示,可知:同一类别的生成数据与原始数据聚集在相同区域,表明生成数据与真实数据的有相似的特征分布。

表 2 为 8 类原始数据与生成数据的均值,对比可知,每类生成数据与原始数据在相对湿度、气

温与热值这三个特征的数值上处于相近的水平,表明生成数据与原始数据基本一致。

综合 8 类原始数据与生成数据 PCA 降维后的特征对比图及每类数据各项特征均值的对比,可知基于 GAN 生成的数据及与之对应的原始数据具有相似性,为垃圾热值预测模型数据集的扩充提供可能,扩充后的数据集可用于建立垃圾热值预测模型。

4.2 模拟数据可靠性评估

为验证 GAN 生成模拟数据的可靠性,调整扩充数据集中添加模拟数据的比例,并计算扩充数据集模拟数据不同占比下模型的均方误差,具体操作如下:最初采用含 100 个真实数据的测试集作为输入,然后从 0 至 100% 按 5% 逐步改变测试集中模拟数据占比,分别计算预测结果与真实值的均方误差,绘制模拟数据不同占比下的预测误差图,如图 7 所示。




图 5 不同季节非节假日原始数据与生成数据特征对比

Fig. 5 Comparison of original data of non-holidays in each season with characteristics of generated data




图 6 不同季节节假日原始数据与生成数据特征对比

Fig. 6 Comparison of original data of each season and holidays with characteristics of generated data

表 2 原始数据与生成数据均值对比

Tab. 2 Comparison of raw data with mean of generated data

数据类别	降雨量/mm		相对湿度/%		气温/℃		热值/(kJ/kg)	
	原始集	生成集	原始集	生成集	原始集	生成集	原始集	生成集
春季非节假日	0.59	0.66	64.34	63.19	22.45	20.89	8 488.06	8 247.60
春季节假日	0.43	0.57	65.64	63.52	21.04	21.23	8 988.99	9 034.57
夏季非节假日	8.00	8.32	67.10	64.28	29.95	28.48	7 593.85	7 648.63
夏季节假日	11.01	9.75	67.07	68.43	28.97	29.79	7 957.12	8 139.21
秋季非节假日	5.51	7.15	61.59	58.78	23.28	21.54	8 650.55	8 398.45
秋季节假日	3.28	6.90	60.94	59.72	23.75	24.16	9 392.14	9 307.50
冬季非节假日	0.26	0.38	56.64	56.99	16.92	16.47	8 065.40	7 993.81
冬季节假日	0.13	0.48	54.76	55.47	17.23	15.39	8 528.47	8 641.97




图 7 不同比例模拟数据预测误差图

Fig. 7 Prediction error plots of simulated data at different scales

随着模拟数据比例增加,预测准确度逐步增加,模拟数据添加约为 85% 时预测精度最高;但当模拟数据添加过多时,预测模型的学习受到限制,反而使预测精度下降。因此,当应用所提出的方案进行垃圾热值预测时,模拟数据占总数据集的 85% 为最佳。

4.3 预测模型准确性验证

为验证模型预测效果,将所提 LS-SVM 垃圾热值预测方案与传统人工智能算法的 BP 与 SVR 垃圾热值预测方案进行对比,分别使用扩充前与扩充后的数据集构建预测模型进行对比试验。计算最大误差 (ME) 与均方根误差 (RMSE),结果如表 3 所示。

表 3 不同预测模型评价指标对比表

Tab. 3 Comparison table of evaluation indicators of different prediction models

算法	未使用 GAN 进行数据集扩充		使用 GAN 进行数据集扩充	
	S_{ME}	S_{RMSE}	S_{ME}	S_{RMSE}
BP	1 547.86	84.29	643.28	49.63
SVR	1 024.79	67.47	503.56	39.28
LS-SVM	807.49	44.23	192.05	15.12

可知:使用生成对抗网络进行数据扩充下的 LS-SVM 预测方案误差最小,准确率最高,验证了基于生成对抗网络的垃圾热值预测算法的准确性。

为进一步反映模型预测效果,分别对数据扩充前后所构建基于 LS-SVM 模型的预测效果进行对比,如图 8 所示,结果表明:使用 GAN 进行数据扩充后的预测结果明显更接近于真实值,有效提高预测精度,预测效果良好。




图 8 不同模型预测效果对比图

Fig. 8 Comparison chart of prediction performance of different models

综上所述,采用 GAN 数据扩充下的 LS-SVM 垃圾热值预测模型精确有效,可很好的实现垃圾热值的提前预测,能够及时的为焚烧炉的燃烧调整提供可靠依据。

5 结 论

本文提出一种基于生成对抗网络的垃圾热值预测模型,利用生成对抗网络生成与原始数据集有相似特征的数据从而扩充建模数据集,以提高模型的预测精度。通过某垃圾焚烧发电厂实际运行数据进行仿真实验,并对模型的可靠性与预测

精度加以验证。本文的主要结论如下:

1)对垃圾热值的影响因素进行分析,确定了五个主要影响因素,分别为:季节性、降雨量、相对湿度、气温及是否为节假日;

2)提出基于 GAN-LSSVM 的垃圾热值数据生成方法。输入真实垃圾热值数据值,通过生成器与判别器的对抗训练,生成与垃圾热值历史数据有相似特征的模拟数据,并通过不同特征与均值水平的对比验证了模拟数据的可靠性;解决垃圾热值预测建模数据集样本不足的问题;

3)利用某垃圾焚烧发电厂的实际运行数据,将所提方案与其他神经网络预测方案进行比较试验,证实使用生成对抗网络扩充建模数据集可以提高垃圾热值预测的准确性。

参考文献:

- [1] 杨涛. 基于经济统计数据的生活垃圾热值计算模型[J]. 环境工程技术学报, 2014, 4 (2): 158-163.
YANG Tao. Economic statistics based municipal solid waste heating value calculation model [J]. Journal of Environmental Engineering Technology, 2014, 4 (2): 158-163 (in Chinese).
- [2] 徐凯, 钟平, 宋金时, 等. 垃圾焚烧电站入炉垃圾低位热值及不确定度研究[J]. 洁净煤技术, 2022, 28 (2): 169-174.
XU Kai, ZHONG Ping, SONG Jinshi, et al. Low level calorific value and uncertainty of waste in MSW incineration power plant [J]. Clean Coal Technology, 2022, 28 (2): 169-174 (in Chinese).
- [3] 马晓茜, 谢泽琼. 基于 BP 神经网络的垃圾热值预测模型[J]. 科技导报, 2012, 30 (23): 46-50.
MA Xiaolian, XIE Zeqiong. Prediction models for the heating values of municipal refuse based on BP neural network [J]. Science & Technology Review, 2012, 30 (23): 46-50 (in Chinese).
- [4] 丁兰, 张文阳, 张良均, 等. 基于人工神经网络的居民生活垃圾可燃成分热值预测[J]. 环境工程学报, 2016, 10 (2): 899-905.
DING Lan, ZHANG Wenyang, ZHANG Liangjun, et al. Prediction of household waste combustible component calorific value based on artificial neural network [J]. Chinese Journal of Environmental Engineering, 2016, 10 (2): 899-905 (in Chinese).
- [5] KUMAR A, SAMADDER S R. Development of lower heating value prediction models and estimation of energy recovery potential of municipal solid waste and RDF incineration [J]. Energy, 2023, 274: 127273.
- [6] SIDDIQUI F Z, ZAIDI S, MANUJA S, et al. Development of models for prediction of the energy content of disposed MSW from an unsecured landfill [J]. Waste Management & Research, 2017, 35 (11): 1129-1136.
- [7] 谢昊源, 黄群星, 林晓青, 等. 基于图像深度学习的垃圾热值预测研究[J]. 化工学报, 2021, 72 (5): 2773-2782.
XIE Haoyuan, HUANG Qunxing, LIN Xiaoqing, et al. Study on the calorific value prediction of municipal solid wastes by image deep learning [J]. CIESC Journal, 2021, 72 (5): 2773-2782 (in Chinese).
- [8] 丁晨曦, 严爱军. 城市生活垃圾热值的特征变量选择方法及预测建模[J]. 北京工业大学学报, 2021, 47 (8): 874-885.
DING Chenxi, YAN Aijun. Characteristic variable selection method and predictive modeling for municipal solid waste heat value [J]. Journal of Beijing University of Technology, 2021, 47 (8): 874-885 (in Chinese).
- [9] ZHU X, YANG G. Study on HHV prediction of municipal solid wastes; a machine learning approach [J]. International Journal of Energy Research, 2022, 46 (3): 3663-3673.
- [10] 杜星宇, 牛冬杰. 上海市生活垃圾低位热值特性预测研究[J]. 广东化工, 2022, 49 (3): 120-122+142.
DU Xingyu, NIU Dongjie. Research on prediction of lower heat value (LHV) characteristics of municipal solid waste in Shanghai [J]. Guangdong Chemical Industry, 2022, 49 (3): 120-122+142 (in Chinese).
- [11] WANG D, TANG Y T, He J, et al. Generalized models to predict the lower heating value (LHV) of municipal solid waste (MSW) [J]. Energy, 2021, 216: 119279.
- [12] 刘怀远, 甄成刚. 基于 WOA-LSSVM 的锅炉 NO_x 排放量预测模型[J]. 华北电力大学学报(自然科学版), 2019, 46 (4): 84-91.
LIU Huaiyuan, ZHEN Chenggang. Prediction model of boiler NO_x emission based on WOA-LSSVM [J]. Journal of North China Electric Power University (Natural Science Edition), 2019, 46 (4): 84-91 (in Chinese).
- [13] 向夏雨, 王佳慧, 王子睿, 等. 基于生成对抗网络技术的医疗仿真数据生成方法[J]. 通信学报, 2022, 43 (3): 211-224.
XIANG Xiayu, WANG Jiahui, WANG Zirui, et al.

Generate medical synthetic data based on generative adversarial network [J]. Journal on Communications, 2022, 43 (3): 211-224 (in Chinese).

[14] 黄灿, 田冷, 王恒力, 等. 基于条件生成式对抗网络的油藏单井产量预测模型 [J]. 计算物理, 2022, 39 (4): 465-478.

HUANG Can, TIAN Leng, WANG Hengli, et al. A single well production forecasting model of reservoir based on conditional generative adversarial net [J]. Chinese Journal of Computational Physics, 2022, 39 (4): 465-478 (in Chinese).

[15] 郭俊锋, 王淼生, 孙磊, 等. 基于生成对抗网络的滚动轴承不平衡数据集故障诊断新方法 [J]. 计算机集成制造系统, 2022, 28 (9): 2825-2835.

GUO Junfeng, WANG Miaosheng, SUN Lei, et al. New method of fault diagnosis for rolling bearing imbalance data set based on generative adversarial network [J]. Computer Integrated Manufacturing System, 2022, 28 (9): 2825-2835 (in Chinese).

[16] 黄棋悦, 严楠, 钟旭佳. 基于生成对抗网络的风电爬坡功率预测 [J]. 太阳能学报, 2023, 44 (1): 226-231.

HUANG Qiyue, YAN Nan, ZHONG Xujia. Wind power ramping events prediction based on generative adversarial network [J]. Acta Energiæ Solaris Sinica, 2023, 44 (1): 226-231 (in Chinese).

[17] 谷琳, 何坤, 刘海威. 中国生活垃圾焚烧发电项目垃圾热值特性及其影响研究 [C]. 中国环境科学学会 2022 年科学技术年会, 南昌, 中国, 2022.

GU Lin, HE Kun, LIU Haiwei. Study on waste heat value characteristics and its impact on waste incineration power generation project in China [C]. 2022 Science and Technology Annual Conference of Chinese Society of Environmental Sciences, Nanchang, China, 2022 (in Chinese).

[18] 李海丹, 郑丽萍, 周涵, 等. 我国生活垃圾组分的时空分布特征回顾 [J]. 环境工程, 2022, 40 (9): 126-134.

LI Haidan, ZHENG Liping, ZHOU Han, et al. Review on spatial-temporal distribution characteristics of municipal solid waste components in China [J]. Environmental Engineering, 2022, 40 (9): 126-134 (in Chinese).

[19] HAN Z, LIU Y, ZHONG M, et al. Influencing factors of domestic waste characteristics in rural areas of developing countries [J]. Waste Management, 2018, 72: 45-54.

[20] 谢焯, 赵闻强, 杨红运, 等. 基于一维深度卷积生成对抗网络的钢轨波磨识别方法 [J]. 铁道建筑, 2022, 62 (12): 62-66+71.

XIE Ye, ZHAO Wenqiang, YANG Hongyun, et al. Rail corrugation identification method based on 1-dimensional deep convolutional generative adversarial networks [J]. Railway Engineering, 2022, 62 (12): 62-66+71 (in Chinese).

[21] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]. Proceedings of the 27th International Conference on Neural Information Processing Systems, Bangkok, Thailand, 2014.

作者简介:

赵征(1978),女,副教授,研究方向为热工过程建模与控制优化,E-mail:zheng_zhao@ncepu.edu.cn;

钟尚峰(1999),女,硕士研究生,研究方向为热工过程控制优化,E-mail:2846075042@qq.com;

任远卓(1997),男,硕士研究生,研究方向为生活垃圾焚烧智能优化;

王浩杰(1999),男,硕士研究生,研究方向为生活垃圾焚烧智能优化。