

引用格式:徐玉韬,王宗义,谈竹奎,等.基于设备状态识别的工业用户低误差碳监测方法[J].电力科学与技术学报,2026,41(2):145-155.

Citation: XU Yutao, WANG Zongyi, TAN Zhukui, et al. Low-error carbon monitoring method for industrial users based on equipment status identification[J]. Journal of Electric Power Science and Technology, 2026, 41(2): 145-155.

# 基于设备状态识别的工业用户低误差碳监测方法

徐玉韬<sup>1</sup>, 王宗义<sup>2</sup>, 谈竹奎<sup>1</sup>, 赵云<sup>2</sup>, 冯起辉<sup>1</sup>, 蔡梓文<sup>2</sup>

(1. 贵州电网有限责任公司电力科学研究院, 贵州 贵阳 550002; 2. 南方电网科学研究院有限责任公司, 广东 广州 510663)

**摘要:**针对现有工业用户碳监测方法精度不足的问题,提出一种基于设备状态识别的工业用户低误差碳监测方法。首先,构建基于时序卷积网络-门控循环单元(temporal convolutional network-gated recurrent unit, TCN-GRU)的设备状态识别模型,精准辨识工业用户关键碳排放设备的运行状态;其次,引入遗传算法(genetic algorithms, GA)动态优化模型全连接层参数,强化分类器对高碳排放设备的识别能力;最后,基于优化后的状态识别结果实现低误差碳排放监测。在工业设备状态识别数据集(industrial appliance identification dataset, IAID)上的实验表明:所提方法显著降低了碳监测误差,均方根误差(root mean square error, RMSE)下降约 13%,且在 RMSE、R<sup>2</sup>等关键指标上均优于现有方法的,有效提升了工业用户碳排放监测的精度与可靠性。

**关键词:**碳监测;设备辨识;遗传算法;TCN-GRU;工业用户

DOI: 10.19781/j.issn.1673-9140.2026.02.013 中图分类号: TM93 文章编号: 1673-9140(2026)02-0145-11

## Low-error carbon monitoring method for industrial users based on equipment status identification

XU Yutao<sup>1</sup>, WANG Zongyi<sup>2</sup>, TAN Zhukui<sup>1</sup>, ZHAO Yun<sup>2</sup>, FENG Qihui<sup>1</sup>, CAI Ziwen<sup>2</sup>

(1. Electric Power Research Institute, Guizhou Power Grid Co., Ltd., Guiyang 550002, China; 2. Southern Power Grid Scientific Research Institute Co., Ltd., Guangzhou 510663, China)

**Abstract:** A low-error carbon monitoring method based on equipment status identification is proposed to solve the problem of insufficient accuracy in existing carbon monitoring methods for industrial users. Firstly, an equipment status identification model based on temporal convolutional network-gated recurrent unit (TCN-GRU) is built to accurately identify the operating status of key carbon-emitting equipment for industrial users. Secondly, genetic algorithms (GAs) are introduced to dynamically optimize the parameters of the fully connected layer in the model, enhancing the classifier's identification capability for equipment with high carbon emissions. Finally, low-error carbon emission monitoring is achieved based on the optimized status identification results. Experiments conducted on the industrial dataset IAID demonstrate that the proposed method significantly reduces carbon monitoring errors, with the root mean square error (RMSE) decreasing by approximately 13%. Additionally, it outperforms existing methods in key metrics such as RMSE and R<sup>2</sup>, effectively improving the accuracy and reliability of carbon emission monitoring for industrial users.

**Key words:** carbon monitoring; device identification; genetic algorithm; TCN-GRU; industrial user

随着全球气候变化问题日益严峻,国家“双碳”战略目标的提出,碳减排已成为推动绿色低碳发展的关键举措<sup>[1-2]</sup>。工业部门的碳排放约占全球碳排放总量的三分之一,成为碳减排工作中的关键领域

之一<sup>[3-4]</sup>。精准的碳排放监测与数据披露能够为制定碳减排策略提供可靠依据<sup>[5]</sup>。因此,精准监测工业碳排放对于实现减排目标至关重要。

近年来,许多国内外学者针对工业用户碳排放

收稿日期:2025-03-08;修回日期:2025-07-26

基金项目:贵州电网公司科技项目(GZKJXM20222127,GZKJXM20222133);国家自然科学基金(52067004)

通信作者:徐玉韬(1982—),男,硕士,正高级工程师,主要从事电网保护与控制、柔性直流配网运行与控制等方面的研究;

E-mail:95616048@qq.com

监测开展系列研究。文献[6]通过分析工艺过程中的物料流,提出将质量平衡法与因子法结合用于监测氧化铝工业的碳排放。文献[7]在分析质量平衡方法并模拟工业生产的基础上,构建了复杂的生产过程模型,以改进质量平衡法实现准确碳排放监测。文献[8]提出3种修正高炉煤气单位热值含碳量的方法,利用实测数据修正排放因子,提高钢铁工业碳排放监测的准确性。文献[9]采用生命周期评估方法构建碳排放监测模型,分析了钢铁行业的生命周期碳排放及减排潜力。文献[10]运用机器学习算法研究水泥企业生产净购入电量与二氧化碳排放总量的关系,分别建立单样本日度电碳监测模型以监测水泥企业碳排放量。然而,上述研究均需较长的时间尺度进行数据统计和分析,难以实现实时监测。

为实现实时监测,文献[11]基于燃料管理系统的常规监测数据,提出了燃煤机组碳排放的快速监测方法,并针对不同工况设计了5种碳排放直接在线监测方法,提升监测精度;文献[12]通过分析微波功率衰减量与飞灰的关系,研发了飞灰烟道式含碳量在线测量系统,克服了传统单点采样型微波测试方法的不足,提高了测量精度;文献[13]结合波长调制-直接吸收光谱(wavelength modulation-direct absorption spectroscopy, WM-DAS)和长光程Herriott池的方法,实现对大气中CO<sub>2</sub>和CH<sub>4</sub>的高效、免标定、高信噪比在线监测。然而,这些方法须安装额外的设备,运维成本较高。因此,文献[14]提出了一种易于实现的基于设备状态识别的实时碳排放监测方法,该方法通过识别设备运行状态并结合相应的排放因子,实现实时监测;文献[15]同样采用设备识别与排放因子实现实时监测,其创新之处在于引入基于超分辨率感知的数据输入网络,以恢复丢失的智能电表数据并提高辨识精度。然而,这些研究普遍未考虑设备在不同运行状态下排放因子的差异,导致设备状态识别精度与碳排放监测误差之间存在复杂的非线性关系,致使实时监测结果仍存在较大偏差。

据此,本文提出一种基于设备状态识别和遗传优化的工业用户低误差碳监测方法。该方法首先建立基于时序卷积网络-门控循环单元(temporal convolutional network-gated recurrent unit, TCN-GRU)的碳排放设备状态识别模型,该模型先利用时序卷积网络(temporal convolutional network, TCN)提取设备功率序列数据的时序特征,结合门

控循环单元(gated recurrent unit, GRU)捕捉长期依赖关系,引入路由注意力机制优化特征选择;再基于梯度下降算法训练辨识网络提取设备运行特征,准确辨识得到工业用户碳排放设备运行状态;最后,以碳监测均方根误差最小为目标,采用遗传算法优化设备识别模型的权重和关键超参数,解决设备识别算法仅关注自身准确率的问题,实现工业用户低误差碳排放监测,并基于公开工业设备数据集开展对比实验和消融实验,验证了所提方法的有效性和优越性。

## 1 工业用户设备级碳监测实现原理

联合国政府间气候变化专门委员会(Intergovernmental Panel on Climate Change, IPCC)在《IPCC 2006年国家温室气体清单指南》2019年修订版中引入了基于排放因子的碳排放分析和核算方法,即为能源消耗量附加一个排放因子(碳排放强度值),排放因子是与能源消耗量相对应的系数<sup>[16]</sup>。该方法的核心是将碳排放源的活动数据和排放因子关联起来,碳排放量为活动数据与排放因子的乘积值,即

$$C = S \cdot e_{\text{DEI}} \quad (1)$$

式中, $C$ 为碳排放量; $S$ 为碳排放源的活动数据; $e_{\text{DEI}}$ 为碳排放因子。

传统碳排放因子法因依赖统计周期数据,存在数据滞后严重、时间粒度较粗、监测精度较低等问题,难以满足工业用户对精细化碳监测的需求。针对上述问题,本文提出了一种基于设备状态识别的工业用户设备级碳监测方法,可实现设备级的精细化碳监测。该方法通过将设备在不同运行状态下的碳排放强度作为该状态的动态碳排放因子,结合各状态下的运行时长,实现设备级精准的碳排放监测与分析。

该方法的核心在于将高精度的设备状态识别和精准的碳排放强度测量相结合,旨在构建设备状态与碳排放之间的映射关系。具体而言,先通过现场测量获取设备在不同运行状态下的碳排放强度基准值,并建立设备碳排放因子库;然后,利用先进的设备状态识别算法,实现对设备运行状态的准确识别;最后,将识别结果与相应的碳排放强度关联,实现碳排放的精准计算

对于某个工业用户,若该用户拥有 $d$ 台设备,在一段时间内其碳排放量的计算式为

$$C_d = \sum_{i=1}^d D_i x \quad (2)$$

式中,  $C_d$  为工业用户在  $x$  小时期间的碳排放总量;  $d$  为直接排放二氧化碳的设备数量;  $D_i$  为设备  $i$  在  $S_i$  状态下的碳排放强度, kg/h。

因此, 通过准确识别工业设备的运行状态, 并将其与预先建立的设备碳排放因子库进行映射计算, 实现对工业用户碳排放的动态、高精度监测。基于设备状态的碳监测方法, 不仅可有效提升监测的准确性, 还可为工业用户制定科学的碳减排策略提供有力的数据支撑。针对不同工业用户, 基于相同原理, 通过识别其设备运行状态并关联对应碳排放强度因子, 即可实现碳排放量的有效监测。

## 2 基于设备状态识别和遗传优化的工业用户低误差碳监测

### 2.1 工业用户设备状态识别

本文提出的低误差碳监测方法首先须准确识别工业用户碳排放设备的运行状态。因此, 本文构建基于 TCN-GRU 的工业用户设备状态识别模型, 该模型由 TCN 模块、GRU 模块和路由注意力模块 3 个部分构成。

为准确识别工业用户碳排放设备的运行状态, 本文建立设备状态识别模型, 先采用 TCN 模块处理设备的功率序列数据。

TCN 可在较长时间范围内选择性地分析功率数据, 有效提取设备运行特征。对工业用户设备的功率序列输入  $x \in R_n$  和特征提取参数  $f: \{0, 1, \dots, k-1\} \rightarrow R$ , TCN 的特征提取范围可通过参数  $k$  和扩张系数  $d$  进行调整, 功率序列特征提取的计算式为

$$F(x) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (3)$$

式中,  $F(x)$  为提取的设备功率特征;  $d$  为扩张系数, 用于调整功率序列的特征提取范围;  $x_{s-d \cdot i}$  为设备历史功率数据;  $k$  为特征提取窗口大小。TCN 对功率序列的特征提取过程由  $k$  和  $d$  共同控制, 使各时刻的输出特征仅依赖于设备的历史功率。

采用 GRU 模块进一步捕捉工业用户设备功率序列的长期依赖关系, 其结构如图 1 所示。

图 1 中, GRU 通过更新门  $z_t$  和重置门  $r_t$  两个门控单元处理功率序列数据, 其计算过程为

$$\begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) = \\ &\sigma(W_{zh} h_{t-1} + W_{zx} x_t + b_z) \end{aligned} \quad (4)$$

$$\begin{aligned} r_t &= \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) = \\ &\sigma(W_{rh} h_{t-1} + W_{rx} x_t + b_r) \end{aligned} \quad (5)$$

$$\begin{aligned} \tilde{h}_t &= \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) = \\ &\tanh(W_{hh} (r_t \odot h_{t-1}) + W_{hx} x_t + b_h) \end{aligned} \quad (6)$$

$$h_t = h_{t-1} \odot z_t + \tilde{h}_t \odot (1 - z_t) \quad (7)$$

式中,  $z_t$  为更新门输出, 用于控制历史功率特征的保留比例;  $r_t$  为重置门输出, 用于控制历史功率特征的遗忘比例;  $h_{t-1}$  为前一时刻的功率状态;  $\odot$  为哈达玛积, 元素级别的乘法;  $x_t$  为当前时刻的设备功率输入;  $\tilde{h}_t$  为候选功率状态;  $h_t$  为当前时刻 GRU 处理后得到的设备功率特征表示;  $W$ 、 $b$  分别为对应的权重矩阵和偏置项。

更新门与重置门的双门控机制使 GRU 能有效捕捉设备功率的长期变化趋势, 实现对设备功率序列的精确建模。再通过引入路由注意力机制精确识别不同特征在工业用户设备状态识别过程中的相对权重, 提升特征选择的精度。路由注意力模块结构如图 2 所示。




图 1 GRU 的结构

Figure 1 GRU structure




图 2 路由注意力模块

Figure 2 Routing attention module

由图 2 可知, 该机制首先将输入的设备状态特征图  $X \in R^{H \times W \times C}$  划分为  $S \times S$  个区域, 每个区域包含  $HW/S^2$  个特征向量, 这些特征向量代表不同的设备状态指标, 通过线性映射获得查询矩阵  $Q$ 、键矩阵  $K$ 、值矩阵  $V$ , 即

$$\begin{cases} Q = X^T W^q \\ K = X^T W^k \\ V = X^T W^v \end{cases} \quad (8)$$

式中,  $W^q$ 、 $W^k$ 、 $W^v$  分别为查询、键和值的投影权重矩阵。

基于本文建立设备状态识别模型构建区域间的特征关联图, 计算每个区域的特征相关性, 其计算式为

$$A^r = Q^r (K^r)^T \quad (9)$$

式中,  $A^r$  为区域间状态特征的相关性矩阵。

为提高特征选择的精确度, 工业用户设备状态识别模型保留每个区域最显著的  $k$  个特征关联, 形成路由索引矩阵。基于该索引矩阵, 模型重点关注最相关区域的特征, 实现细粒度的特征关联分析, 从而准确识别不同设备状态特征之间的相对重要性, 由此提高设备状态识别的准确性。

综上所述, 工业用户设备状态识别模型通过 TCN 多尺度时序特征提取、GRU 长期记忆机制以及路由注意力精确特征选择, 实现工业用户设备状态的精确识别, 为后续碳监测优化提供基础。

## 2.2 碳排放监测遗传优化

提高设备状态识别的准确性可提升碳排放监测的准确性, 但设备状态识别精度与碳排放监测精度的目标并不完全一致, 两者不能等同。这是因为两者之间的关系并非简单的线性关系, 且提高设备状态识别的准确性有时会导致碳排放监测误差增大。因此, 仅考虑高准确率的设备状态识别不足以实现工业用户低误差的碳监测。

遗传算法在处理设备状态辨识的多参数组合优化问题上具有显著优势, 其核心价值体现于 3 个方面: 一是通过动态调节模型关注权重, 定向提升高碳排放设备的识别精度; 二是凭借灵活的优化机制有效规避局部最优解; 三是依托高效计算特性满足工业场景实时需求。相较而言, 传统优化算法往往存在计算复杂度过高或异构设备兼容性不足的局限, 而遗传算法在精度优化、全局收敛与工程适用性之间实现了更优的均衡。因此, 考虑到实际应用效果, 本文采用遗传算法优化碳排放监测误差, 以解决设备状态识别精度与碳监测误差间的非线性关系所导致的碳监测精度问题。

本文提出基于遗传算法的碳排放监测优化框架, 该框架中的每个染色体编码表示一组候选解决方案, 其包含影响设备状态识别和碳排放监测精度的超参数组合, 包括分类器类型及其超参数、高碳排放设备状态识别权重等关键参数。碳排放监测优化以碳监测均方根误差 (root mean square error, RMSE) 作为适应度函数, 通过最小化碳监测均方根

误差值, 求解最优超参数配置, 实现碳监测误差最小化。通过遗传算法优化设备状态识别模型的权重及参数, 该方法由追求模型总体识别精度转向聚焦高碳排放设备的状态识别精度提升。此举旨在降低碳排放监测误差, 从而缓解因设备状态识别精度与碳监测误差间非线性关系导致的碳监测偏差问题。该方法具有普适性, 可推广应用于任何具备明确碳排放设备的工业场景。碳排放监测遗传优化伪代码见表 1。

表 1 碳排放监测遗传优化的伪代码

Table 1 Pseudocode for genetic optimization of carbon emission monitoring

基于遗传算法的工业用户碳排放监测误差优化	
输入: 训练数据集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$	
1:	设置参数: $P_{size}, I_{max}, p_c, p_m, d_p$
2:	初始化种群: $P_i = [\theta_i, \omega_i, \lambda_i], i \in \{1, 2, \dots, P_{size}\}$
3:	计算适应度: $F(P_i) = R(P_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_i - \hat{C}_i)^2}$
4:	初始化最优解: $P_{best} = \min \{F(P_i)\}$
5:	$k=1$
6:	WHILE $k < I_{max}$
	选择操作:
7:	$P_i^s = \operatorname{argmax}_{P_j \in \mathcal{P}} \{F(P_j)\}$
	交叉操作:
8:	IF $\{\text{random} < p_c\}$ THEN
	$\begin{cases} P_i^c = \alpha P_i^s + (1 - \alpha) P_{i+1}^s \\ P_{i+1}^c = (1 - \alpha) P_i^s + \alpha P_{i+1}^s \end{cases}$
9:	END IF
	变异操作:
10:	IF $\{\text{random} < p_m\}$ THEN
	$P_i^m = P_i^c + N(0, \sigma^2)$
	END IF
	计算适应度: $F(P_i^m) = R(P_i^m)$
11:	IF $\{\min \{F(P_i^m)\} < F(P_{best})\}$ THEN
	$P_{best} = \operatorname{argmin} \{F(P_i^m)\}$
12:	END IF
13:	END IF
14:	$k=k+1$
15:	END WHILE
输出: $P_{best}$	

由表 1 可知, 本文提出的碳排放监测遗传优化算法采用实数编码策略, 将工业用户设备状态识别模型参数  $\theta$ 、状态识别权重  $\omega$  和高碳排放系数  $\lambda$  编码为染色体, 以训练数据集  $D$  为输入, 通过设定种群规模  $P_{size}$ 、最大迭代次数  $I_{max}$ 、概率  $p_c$ 、变异概率  $p_m$  和

问题维度  $d_p$  等关键参数,构建以碳监测均方根误差 RMSE 为核心的适应度函数,其计算式为

$$F(P_i) = R(P_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_i - \hat{C}_i)^2} \quad (10)$$

式中,  $P_i$  为第  $i$  个染色体;  $F(P_i)$  为适应度函数;  $R(P_i)$  为碳监测均方根误差;  $C_i$  为第  $i$  个样本的碳排放实测值;  $\hat{C}_i$  为第  $i$  个样本的碳排放监测值;  $n$  为训练数据集的样本数量。

在优化过程中,算法通过锦标赛选择机制筛选优质个体,并结合算术交叉和高斯变异操作,实现种群进化。为确保解的收敛性,采用精英保留策略,持续更新全局最优解  $P_{\text{best}}$ ,碳监测遗传优化的计算过程为

$$P_i^s = \operatorname{argmax}_{P_j \in \mathcal{T}} \{F(P_j)\} \quad (11)$$

$$\begin{cases} P_i^c = \alpha P_i^s + (1 - \alpha) P_{i+1}^s \\ P_{i+1}^c = (1 - \alpha) P_i^s + \alpha P_{i+1}^s \end{cases} \quad (12)$$

$$P_i^m = P_i^c + N(0, \sigma^2) \quad (13)$$

$$P_{\text{best}} = \operatorname{argmin} \{F(P_i^m)\} \quad (14)$$

式中,  $\mathcal{T}$  为从种群中随机抽取的  $k$  个染色体组成的子集;  $\operatorname{argmax}$  为目标值取最大值时对应的参数算子;  $P_i^s$  为锦标赛选择后的染色体;  $\alpha$  为交叉系数,表示父代染色体的线性组合比例;  $P_i^c$  为算术交叉后的染色体;  $N(0, \sigma^2)$  表示均值为 0、方差为  $\sigma^2$  的高斯分布;  $\operatorname{argmin}$  为目标值取最小值时对应的参数算子。

碳监测误差优化利用遗传算法的全局搜索能力有效解决碳排放监测中设备状态识别精度与碳监测误差之间的非线性优化问题,最终可获得设备状态识别模型的最优参数配置,实现碳排放监测误差最小化。

### 2.3 工业用户低误差碳监测方法具体实现流程

基于设备状态识别和遗传优化的工业用户低误差碳监测方法的具体实现流程如图 3 所示。方法具体步骤如下:

1) 获取本文提出碳监测方法所需数据,包括工业用户设备功率数据、设备运行状态数据和设备碳排放强度数据;

2) 分析处理原始数据,包括归一化工业用户设备功率数据并计算得到各设备碳排放矩阵,构建本文提出设备状态识别模型数据集,并将数据集划分为训练集和测试集;

3) 建立评价指标,包括设备状态识别评价指标和碳监测评价指标;

4) 利用 TCN 模块提取工业用户碳排放设备功率序列数据时序特征;

5) 采用 GRU 模块进一步捕捉设备功率序列数据的长期依赖关系;

6) 通过路由注意力机制提高特征选择精度;

7) 利用基于 TCN-GRU 的设备状态识别模型准确识别工业用户碳排放设备状态;

8) 基于遗传算法优化碳排放设备状态识别模型,调整模型关键超参数,并迭代训练模型;

9) 在每轮训练完成后评估碳监测误差值是否下降至最小,若已降至最小则停止训练并保存最优模型参数,否则继续训练模型;

10) 调用最优模型进行设备状态识别并计算碳排放量,最终实现工业用户碳排放准确监测。

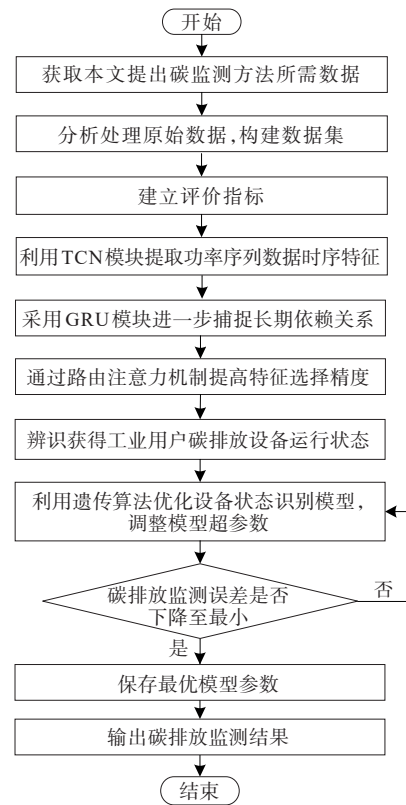


图 3 本文提出碳监测方法的具体实现流程

Figure 3 Specific implementation process of the proposed carbon monitoring method

## 3 实验验证与分析

为验证本文提出的基于设备状态识别和遗传优化的工业用户低误差碳监测方法的准确性和有效性,采用国际公认的工业设备状态识别数据集 (industrial appliance identification dataset, IAID) 作为实验数据集,基于多场景的工业用户数据集对所提方法的准确性和有效性进行验证。本文实验均在 Python3.8.5 环境下进行,本文建立的工业用户

设备状态识别模型采用 Pytorch 框架实现,计算机硬件配置为 AMD Ryzen 9 7945HX CPU, NVIDIA GeForce RTX 4060 Laptop GPU, 32 GB RAM, 操作系统为 Windows 11。

### 3.1 数据集分析与处理

IAID 数据集由钢铁、金属、化工、塑料、玻璃、纺织六大工业用户的设备功率数据、设备状态及设备碳排放强度组成,包括多个工业用户一个月内 1 Hz 低频总功率数据  $P$ ,并以 5 min 为时间尺度记录设备运行状态,共计 8 640 个设备状态数据<sup>[17]</sup>。在实际工业用户碳排放监测过程中,须采集工业设备的负荷数据及其对应运行状态,并获取不同状态下的碳排放强度因子。负荷数据可通过电表获取,若设备存在预设运行状态,则直接采用;若无预设状态,则须依据负荷强度特征对设备状态进行划分。设备碳排放强度因子的获取难度较大,通常需通过物料平衡法进行标定。

针对不同行业工厂特点,本文选取 IAID 数据集中的 5 家工厂(钢铁厂、金属厂、化工厂、塑料厂、玻璃厂)碳排放设备状态进行分析,工业用户碳排放设备及其状态组合见表 2。

表 2 工业用户碳排放设备及其状态组合

Table 2 Carbon emission equipment of industrial users and its status combination

工业用户	碳排放设备	设备状态组合/种
钢铁厂	电弧炉 I、电弧炉 II	15
金属厂	电热处理炉	4
玻璃厂	电热炉、电动回火炉	12 (3,4)
塑料厂	注塑机	3
化工厂	反应槽	4

工业用户的碳排放设备运行状态多样,且不同设备的运行状态可形成多种状态组合。以玻璃厂为例,其碳排放设备包括电热炉和电动回火炉,分别有 3、4 种状态,因此,碳排放设备的状态组合总数为 12 种。对于钢铁厂,其碳排放设备包括电弧炉 I 和电弧炉 II,每种设备都有 4 种不同的状态,理论上组合后共有 16 种状态,但由于本文采用的数据集中不存在电弧炉 I 为 2 状态、同时,电弧炉 II 为 1 状态这一状态组合情况,因此,钢铁厂的碳排放设备状态组合实际为 15 种。对不同类型的钢铁厂,鉴于其工艺流程存在差异性,其设备规模与规格亦可能有所不同,故须根据实际情况调整相应参数。

为提升所提设备状态识别模型的收敛速度与泛化能力,对数据集中的工业设备功率数据进行归一化处理,将功率值映射至  $[0, 1]$ ,其计算式为

$$\widetilde{P}_t = \frac{P_t - P_{\min}}{P_{\max}} \quad (15)$$

式中,  $\widetilde{P}_t$  为  $t$  时刻归一化后功率值;  $P_{\max}$ 、 $P_{\min}$  分别为整个功率序列的最大、最小值。

同时,为便于后期准确计算碳排放设备的碳排放量,本文对设备碳排放强度数据进行处理,计算出各工业用户的碳排放设备所有状态对应的碳排放强度,并在模型代码中以矩阵形式表达。以钢铁厂为例,其碳排放设备对应的 15 种组合状态的碳排放强度可用  $1 \times 15$  的矩阵来表示,即

$$S_c = \begin{bmatrix} 0, & 151.09, & 176.928 & 333 & 3 \\ 164.096 & 666 & 7, & 2.789 & 166 & 667, & 153.879 & 166 & 7 \\ 179.717 & 5, & 166.885 & 833 & 3, & 2.928 & 333 & 333 \\ 179.856 & 666 & 7, & 167.025, & 2.640 & 833 & 333 \\ 153.730 & 833 & 3, & 179.569 & 166 & 7, & 166.737 & 5 \end{bmatrix} \quad (16)$$

式中,  $S_c$  为钢铁厂碳排放设备的碳排放强度矩阵,矩阵中的每个数值对应每种状态组合的碳排放强度值。

### 3.2 评价指标建立

评价指标在评价模型质量方面发挥着重要作用,不同的实际应用需采用特定的评价指标。本文采用准确率  $e_{\text{ACC}}$  与调和平均数  $F_1$  作为指标,评价设备状态识别模型的性能,其中准确率  $e_{\text{ACC}}$  为预测正确个数与预测总数的比值,与设备状态识别模型在所有类别中的整体性能有关,其计算式为

$$e_{\text{ACC}} = \frac{T_p + T_n}{T_p + F_p + T_n + F_n} \times 100\% \quad (17)$$

式中,  $T_p$  为样本的真实类别是正类,且设备状态识别模型预测的结果同是正类;  $F_p$  为样本的真实类别是负类,但设备状态识别模型将其预测成为正类;  $F_n$  为样本的真实类别是正类,而设备状态识别模型将其预测为负类。

此外,考虑到设备状态的不平衡性,本文采用调和平均数  $F_1$  对模型进行评价,即

$$\begin{cases} e_{\text{REC}} = \frac{T_p}{T_p + F_n} \times 100\% \\ e_{\text{PRE}} = \frac{T_p}{T_p + F_p} \times 100\% \\ F_1 = \frac{2e_{\text{PRE}}e_{\text{REC}}}{e_{\text{PRE}} + e_{\text{REC}}} \times 100\% \end{cases} \quad (18)$$

然而,仅考虑设备状态识别的准确率等指标是不够的。因此,有必要考虑碳排放监测回归性能的评价指标。对于碳排放监测的评价,本文采用  $e_{R^2}$  和  $e_{RMSE}$  作为其评价指标,即

$$e_{R^2} = 1 - \frac{\sum_{i=1}^{N_s} (\hat{C}_i - C_i)^2}{\sum_{i=1}^{N_s} (C_i - \bar{C})^2} \quad (19)$$

$$e_{RMSE} = \sqrt{\frac{1}{N_s} \sum_{i=1}^{N_s} (C_i - \hat{C}_i)^2} \quad (20)$$

式中,  $N_s$  为预测子功率序列总数;  $\hat{C}_i$ 、 $C_i$ 、 $\bar{C}$  分别为第  $i$  次序列碳排放监测值、碳排放实测值和实际碳排放平均值;  $e_{R^2}$  为衡量碳排放监测回归性能的指标,表示自变量对因变量的解释能力,其取值范围为  $[0, 1]$ ;  $e_{RMSE}$  为均方根误差,能够反映碳监测误差的绝对值大小。

### 3.3 碳排放设备状态识别实验

为验证所提基于 TCN-GRU 的设备状态识别模型的有效性,采用该模型对钢铁厂、金属厂、化工厂、塑料厂、玻璃厂 5 个工业用户进行设备状态识别验证。实验中,设备状态识别模型利用多组参数配置进行训练,并在测试集上评估其性能,选择在测试集上表现最佳的一组参数作为模型参数,参数设置见表 3。

表 3 模型网络结构参数设置

Table 3 Parameter setting of model network structure

模块	一级指标	参数可选范围	参数设置
TCN	输入序列长度	任意正整数	300
	Kernel Size	3, 5, 7 等	3
	Channels	16, 32, 64 等	32
	激活函数	ReLU, Tanh 等	
	Input Dim	16, 32, 64 等	32
GRU	Hidden Dim	32, 64, 128 等	64
	GRU 层数	$\geq 1$	2
	时间步长	任意正整数	300
	Top-K 值	2, 4, 8 等	4
Routing Attention	Dim	32, 64, 128 等	64
	路由激活函数	Softmax 等	
	缩放因子(Scale)	可选浮点数	$64^{-0.5}$

由表 3 可知,选择 ReLU 作为 TCN 的激活函数是因为在训练深层网络时,ReLU 能够有效避免梯度消失问题,且计算效率高。而路由注意力模块采用 Softmax 作为激活函数的原因在于 Softmax 相比其他激活函数在多分类任务中表现更好,可有效将

特征权重归一化。

以玻璃厂为例,采用本文提出设备状态识别模型对其数据进行训练,数据集被分为训练集和测试集,固定比例为 6:4,模型训练 epoch 设置为 80。若在 80 个 epoch 后未收敛,则对模型学习率进行调整以达到模型收敛,玻璃厂设备状态识别准确率与  $F_1$  值随模型迭代次数的变化情况如图 4 所示。




图 4 玻璃厂设备状态识别准确率与  $F_1$  曲线

Figure 4 Equipment status identification accuracy of a glass plant and  $F_1$  curve

由图 4 可见,随着设备状态识别模型迭代次数递增,玻璃厂的设备状态识别准确率和  $F_1$  值总体上均呈现逐步上升的趋势,且两者的变化趋势较为一致。在第 44 次迭代时,设备状态识别模型的准确率出现显著下降,原因在于模型学习率等参数更新速度过快,优化过程偏离全局最优解。为解决这一问题,本文在模型再训练过程中引入了学习率自适应调整机制,通过动态降低学习率以减小梯度更新的幅度,有效提升模型收敛稳定性。

随着模型迭代过程持续深入,其性能指标得到显著提升。在第 70 次迭代时,模型趋于收敛,最终设备状态识别准确率高达 96.47%、 $F_1$  值高达 96.57%,已完全满足工业用户设备状态识别要求。

为验证本文提出设备状态识别模型在不同工业场景中的普适性,针对钢铁厂、金属厂等 5 个工业用户进行设备状态识别实验,结果见表 4。

表 4 各工业用户设备状态识别结果

Table 4 Equipment status identification results of each industrial user

工业用户	$e_{Acc}$	$F_1$
钢铁厂	94.56	93.56
金属厂	91.32	89.20
玻璃厂	96.47	96.57
塑料厂	93.98	88.56
化工厂	84.90	78.41

由表4可知,本文提出设备状态识别模型在钢铁厂、金属厂、玻璃厂及塑料厂的识别准确率均在91%以上。然而,化工厂的设备状态识别准确率及 $F_1$ 值较低,这一结果的主要原因在于该工业用户数据集的多样性较差,模型难以有效提取数据特征,而非模型本身的性能问题。

综上所述,本文提出基于TCN-GRU的设备状态识别模型在5个工业用户案例中均表现优异,可实现碳排放设备状态精准识别。

### 3.4 碳排放监测与误差优化

为提高工业用户碳监测精度,本节采用遗传算法对监测误差进行目标优化实验。在该实验中,本文将未采用遗传算法(genetic algorithms, GA)进行优化与采用GA进行优化的两种情况进行对比,评价指标为 $e_{R^2}$ 和 $e_{RMSE}$ ,其对比结果如表5所示。

表5 遗传算法引入前后对比结果

Table 5 Comparison results before and after GA introduction

工业用户	未引入GA		引入GA	
	$e_{RMSE}$	$e_{R^2}$	$e_{RMSE}$	$e_{R^2}$
钢铁厂	5.896 9	0.994 6	4.304 7	0.996 9
金属厂	1.089 3	0.697 2	0.879 1	0.824 5
玻璃厂	1.987 4	0.986 9	1.892 7	0.992 1
塑料厂	6.254 7	0.728 7	5.379 0	0.805 7
化工厂	3.025 8	0.475 2	3.025 8	0.475 2

由表5可知,在引入了遗传算法后,钢铁厂、金属厂、玻璃厂和塑料厂等工业用户的碳监测误差(即 $e_{RMSE}$ 值)均明显降低。其中,碳监测误差下降最为显著的是钢铁厂和金属厂,其 $e_{RMSE}$ 值分别降低27%和19.3%。对于5个工业用户,其碳监测误差整体上平均降低13%。且在钢铁厂、金属厂、玻璃厂和塑料厂4个工业用户场景中,碳排放监测的 $e_{R^2}$ 值均在0.8以上,具体分别为0.996 9、0.824 5、0.992 1和0.805 7。然而,化工厂碳监测优化前后的 $e_{R^2}$ 值和 $e_{RMSE}$ 值无显著变化,其主要原因在于化工厂的数据特征维度不足,限制了设备状态识别模型的判别能力,因此难以提升 $e_{R^2}$ 拟合度并降低碳监测误差。

综上所述,通过引入遗传算法进行碳监测优化,有效提升了碳排放监测精度。这一结果表明,遗传算法在处理复杂非线性问题方面具有显著优势,可有效增强本文提出碳监测方法的准确性。

以钢铁厂为例,计算其24 h内碳排放实际量与碳排放监测量,并将两个值进行对比,其对比结果如图5所示。从图5中可以看出,碳排放监测量(虚

线)与实际碳排放量(实线)基本吻合,其原因在于本文提出设备状态识别模型在钢铁厂24 h内的设备状态识别中未出现误差,故其碳排放监测结果完全准确。其中,前8 h碳排放量稳定维持在167 kg左右,随后持续下降,至第16 h降至0 kg。这一现象主要归因于钢铁厂内主要碳排放设备电弧炉I和电弧炉II停止运行,碳排放活动终止。




图5 钢铁厂碳排放量24小时内监测结果对比

Figure 5 Monitoring result comparison of carbon emissions for steel plants within 24 hours

为进一步验证本文提出基于设备状态识别和遗传优化的工业用户低误差碳监测方法的优越性,将所提方法与K近邻算法(k-nearest neighbors, KNN)、决策树(decision tree, DT)、SE-LSTM<sup>[18]</sup>、岭回归分类(Ridge)、卷积神经网络(convolutional neural network, CNN)、随机森林(random forest, RF)及CNN-BiLSTM<sup>[19]</sup>等常用算法进行比较,在钢铁厂、金属厂和玻璃厂等工业数据集上进行实验。方法对比结果如表6所示。

由表6可知,本文提出碳监测方法在3类工业场景中均取得了最优结果。具体而言,在钢铁厂场景中,本文提出碳监测方法的设备状态识别准确率( $e_{Acc}$ )达到94.56%, $F_1$ 值达到93.56%,且碳监测均方根误差( $e_{RMSE}$ )仅为4.304 7, $e_{R^2}$ 值高达0.996 9,相比其他方法均有显著提升。在金属厂和玻璃厂场景中,本文提出碳监测方法同样表现优异:设备状态识别准确率分别达到91.32%和96.47%, $F_1$ 值分别达到89.20%和96.57%,RMSE分别降至0.879 1和1.892 7。值得注意的是,本文提出方法在3个工业用户数据集上的 $e_{R^2}$ 值均接近1,分别为0.996 9、0.824 5和0.992 1,表明该方法具有极强拟合能力,充分验证了其在工业用户碳监测任务中的有效性。

表 6 方法对比结果  
Table 6 Comparison results of methods

方法	钢铁厂				金属厂				玻璃厂			
	$e_{Acc}/\%$	$F_1/\%$	$e_{RMSE}$	$e_{R^2}$	$e_{Acc}/\%$	$F_1/\%$	$e_{RMSE}$	$e_{R^2}$	$e_{Acc}/\%$	$F_1/\%$	$e_{RMSE}$	$e_{R^2}$
KNN	78.68	74.30	24.652 1	0.133 3	89.38	88.36	1.093 8	0.627 7	83.67	80.30	6.238 9	0.482 9
DT	76.15	77.61	18.526 4	0.772 1	89.34	88.92	1.354 1	0.705 2	86.32	85.55	3.615 7	0.743 3
SE-LSTM	89.75	87.02	9.246 3	0.978 2	83.52	81.65	1.985 4	0.756 0	92.06	91.65	2.038 5	0.878 2
Ridge	49.63	48.41	154.236 5	0.207 6	48.25	46.55	34.518 6	0.172 5	59.80	52.22	39.415 2	0.218 0
CNN	87.63	87.02	5.217 4	0.880 6	87.28	85.36	0.998 1	0.810 8	93.55	89.67	2.328 5	0.937 4
RF	85.25	74.27	8.971 3	0.892 9	88.47	84.69	1.357 2	0.764 1	94.74	90.71	2.003 6	0.970 5
CNN-BiLSTM	78.73	76.36	21.547 8	0.797 8	87.02	81.78	1.259 1	0.744 5	85.20	83.22	3.654 1	0.874 1
本文所提	94.56	93.56	4.304 7	0.996 9	91.32	89.20	0.879 1	0.824 5	96.47	96.57	1.892 7	0.992 1

通过对比分析可知,传统机器学习方法(KNN、DT和Ridge)在3种工业场景中性能表现相对不足。其中,Ridge算法的各项评价指标均显著低于其他方法。深度学习方法(SE-LSTM、CNN和RF)虽取得较优结果,但在RMSE和ACC等关键指标上仍与本文提出方法存在差距。实验结果表明,本文提出碳监测方法在工业用户碳排放监测任务中具有明显优势,可更好地满足实际工业场景对碳排放监测精度的需求。

### 3.5 消融实验

为验证本文提出工业用户设备状态识别模型中各模块的重要性,本节开展了模型消融实验。实验分别对比了加入路由注意力机制的TCN模型、加入路由注意力机制的GRU模型、TCN-GRU模型以及本文提出设备状态识别模型在钢铁厂和金属厂数据集上的设备状态识别效果及碳排放监测效果,对比结果如表7所示。

表 7 消融实验结果  
Table 7 Ablation experiment results

模型	钢铁厂			金属厂		
	$e_{Acc}/\%$	$F_1/\%$	$e_{RMSE}$	$e_{Acc}/\%$	$F_1/\%$	$e_{RMSE}$
TCN+路由注意力	80.84	75.93	80.564 8	74.65	58.18	107.291 4
GRU+路由注意力	88.66	86.48	36.176 1	85.24	83.82	25.363 9
TCN-GRU	91.28	89.83	22.446 8	89.77	86.03	6.192 7
本文提出模型	94.56	93.56	5.896 9	91.32	89.20	1.089 3

由表7可知,由于加入路由注意力机制的TCN模型对工业设备功率数据长期依赖关系的捕捉能力不足,设备状态识别效果较差,在金属厂的设备状态识别准确率仅为74.65%。加入路由注意力机制的GRU模型在设备状态识别准确率和 $F_1$ 值上有所提升,但碳排放监测的 $e_{RMSE}$ 值仍较高,分别为36.176 1和25.363 9。TCN-GRU模型表现显著提升,钢铁厂和金属厂的准确率分别达到91.28%和89.77%, $e_{RMSE}$ 值分别降至22.446 8和6.192 7,表明其综合性能优于前述模型。而本文提出设备状态识别模型在TCN-GRU的基础上引入路由注意力机制,模型特征选择精度进一步提高,在钢铁厂和金属厂数据集上的准确率分别达到94.56%和91.32%, $e_{RMSE}$ 值分别降至5.896 9和1.089 3,显著降低了碳排放监测误差。

综上所述,本文提出设备状态识别模型在钢铁厂和金属厂数据集上的设备状态识别效果均优于其他模型,且在碳排放监测环节具有更高精度,验证了本文提出设备状态识别模型各模块在提升模型性能中的关键作用。

## 4 结语

为提升工业用户碳监测精度,本文创新性地提出了一种基于设备状态识别的工业用户低误差碳监测方法,实验结果表明:

- 1) 所构建的TCN-GRU设备状态识别模型,有效解决长时间序列特征提取难题,在工业用户设备功率序列识别上表现优异,最高识别准确率达96.47%,显著提升了设备状态识别精度;

2) 基于上述识别结果,引入遗传优化策略,构建低误差碳监测模型,成功将碳排放监测的RMSE平均降低约13%,解决了“识别准但监测不准”的痛点。

综上所述,本方法显著提升了工业用户碳排放监测的准确度,为碳减排决策提供坚实的数据基础。

#### 参考文献:

- [1] 刘天蔚,边晓燕,吴珊,等. 电力系统碳排放核算综述与展望[J]. 电力系统保护与控制, 2024, 52(4): 176-187.  
LIU Tianwei, BIAN Xiaoyan, WU Shan, et al. Overview and prospect of carbon emission accounting in electric power systems[J]. Power System Protection and Control, 2024, 52(4): 176-187.
- [2] 李昌陵,常喜强,卢浩. 新疆能耗双控向碳排放双控转变分析和预测[J]. 发电技术, 2024, 45(6): 1114-1120.  
LI Changling, CHANG Xiqiang, LU Hao. Analysis and forecast of the shift from double control of energy consumption to double control of carbon emissions in Xinjiang[J]. Power Generation Technology, 2024, 45(6): 1114-1120.
- [3] 赵宇,贺兴,艾芊. 基于碳流追踪的电动汽车充电站定价方法[J]. 电力工程技术, 2025, 44(6): 2-12.  
ZHAO Yu, HE Xing, AI Qian. Pricing method for electric vehicle charging stations based on carbon flow tracing[J]. Electric Power Engineering Technology, 2025, 44(6): 2-12.
- [4] 易涛,王鹏博,刘源,等. 自愿减排市场下发电主体交易策略[J]. 电力建设, 2025, 46(12): 20-32.  
YI Tao, WANG Pengbo, LIU Yuan, et al. Trading strategies of power generation entities in the voluntary emission reduction market[J]. Electric Power Construction, 2025, 46(12): 20-32.
- [5] 张裕,李庆生,罗宁. 面向低碳经济目标的输配电系统协同电网扩展规划[J]. 高压电器, 2025, 61(5): 247-257.  
ZHANG Yu, LI Qingsheng, LUO Ning. Collaborative power grid expansion planning of transmission and distribution system towards low-carbon economic target [J]. High Voltage Apparatus, 2025, 61(5): 247-257.
- [6] 许乐,徐玉韬,袁旭峰,等. 计及动态碳排的含氢综合能源系统低碳调度[J]. 电网与清洁能源, 2025, 41(2): 120-129.  
XU Le, XU Yutao, YUAN Xufeng, et al. Low-carbon dispatching of hydrogen-based integrated energy systems considering dynamic carbon emissions[J]. Power System and Clean Energy, 2025, 41(2): 120-129.
- [7] LIU Z, DENG Z, DAVIS S, et al. Monitoring global carbon emissions in 2022[J]. Nature Reviews Earth & Environment, 2023, 4(4): 205-206.
- [8] GAO Y P, WANG J Z, ZHU Y Q, et al. Real time estimation of carbon emissions for industrial users based on load monitoring in advanced metering infrastructure [J]. Journal of Cleaner Production, 2024, 483: 144226.
- [9] LIU T T, WANG Q W, SU B. A review of carbon labeling: Standards, implementation, and impact[J]. Renewable and Sustainable Energy Reviews, 2016, 53: 68-79.
- [10] 李春焕,曹阿林. 氧化铝工业碳排放核算方法[J]. 有色金属(冶炼部分), 2023(5): 26-31+91.  
LI Chunhuan, CAO Alin. Carbon emission accounting methods of alumina industry[J]. Nonferrous Metals (Extractive Metallurgy), 2023(5): 26-31+91.
- [11] YU S J, LIN F J, ZHAO G, et al. Accurate carbon accounting based on industrial metabolism for the lean management of carbon emission[J]. Energy Reports, 2023, 9: 3872-3880.
- [12] 万迎峰,李秋军,潘书婷,等. 基于实测数据的高炉煤气单位热值含碳量推荐值的修正方法[J]. 洁净煤技术, 2024, 30(8): 75-81.  
WAN Yingfeng, LI Qiujun, PAN Shuting, et al. Correction method of the recommended value of carbon content per unit calorific value of blast furnace gas based on measured data[J]. Clean Coal Technology, 2024, 30(8): 75-81.
- [13] 宋晓聪,杜帅,邓陈宁,等. 钢铁行业生命周期碳排放核算及减排潜力评估[J]. 环境科学, 2023, 44(12): 6630-6642.  
SONG Xiaocong, DU Shuai, DENG Chenning, et al. Life cycle carbon emission accounting and emission reduction potential assessment of steel industry[J]. Environmental Science, 2023, 44(12): 6630-6642.
- [14] 张舒涵,陈晖,王彬,等. 基于水泥企业电-碳关系的碳排放监测[J]. 中国环境科学, 2023, 43(7): 3787-3795.  
ZHANG Shuhan, CHEN Hui, WANG Bin, et al. Carbon emission monitoring based on analysis from "electricity-carbon" relationship of cement enterprises[J]. China Environmental Science, 2023, 43(7): 3787-3795.
- [15] 韩金克,吴建群,夏永俊,等. 700 MW燃煤发电机组二氧化碳排放在线监测方法对比研究[J]. 热力发电, 2025, 54(1): 153-161.  
HAN Jinke, WU Jianqun, XIA Yongjun, et al. Comparative study on online monitoring methods for carbon dioxide emissions of 700 MW coal-fired power plants[J]. Thermal Power Generation, 2025, 54(1): 153-161.

- [16] 李强, 宣益民, 冯长青, 等. MCE-1 型烟道式飞灰含碳量在线测量系统的研制[J]. 工程热物理学报, 2003, 24(3): 523-526.  
LI Qiang, XUAN Yimin, FENG Changqing, et al. Development of mce-1 carbon-in-ash measuring system on-line non-extractive[J]. Journal of Engineering Thermophysics, 2003, 24(3): 523-526.
- [17] 王振, 杜艳君, 丁艳军, 等. 波长调制-直接吸收方法在线监测大气中  $\text{CH}_4$  和  $\text{CO}_2$  浓度[J]. 物理学报, 2020, 69(6): 107-114.  
WANG Zhen, DU Yanjun, DING Yanjun, et al. Monitoring of ambient methane and carbon dioxide concentrations based on wavelength modulation direct absorption spectroscopy[J]. Acta Physica Sinica, 2020, 69(6): 107-114.
- [18] LIU G L, LIU J J, ZHAO J H, et al. Real-time corporate carbon footprint estimation methodology based on appliance identification[J]. IEEE Transactions on Industrial Informatics, 2023, 19(2): 1401-1412.
- [19] LIU J J, LIU G L, ZHAO H, et al. Real-time industrial carbon emission estimation with deep learning-based device recognition and incomplete smart meter data[J]. Engineering Applications of Artificial Intelligence, 2024, 127: 107272.
- [20] 李霞. 我国二氧化碳排放区域差异研究: 基于 IPCC 碳排放核算方法[J]. 国土与自然资源研究, 2013(2): 63-65.  
LI Xia. An Research on Regional Differences of China's Carbon Dioxide Emissions: Based on The IPCC carbon emissions accounting method[J]. Territory & Natural Resources Study, 2013(2): 63-65.
- [21] HWANG H, KANG S. Nonintrusive load monitoring using an LSTM with feedback structure[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2509111.
- [22] 刘青, 李奥龙, 马创, 等. 基于 Lissajous 曲线和 YOLOv8 的电能质量扰动识别方法[J]. 智慧电力, 2025, 53(11): 109-115.  
LIU Qing, LI Aolong, MA Chuang, et al. A power quality disturbance identification method based on lissajous curve and YOLOv8 network[J]. Smart Power, 2025, 53(11): 109-115.