

# 基于TCN-GAT与混合神经网络的汽车涂装 烘干系统能耗异常检测

李聪波 翟贺旺 吴畏\* 董可 张祥飞

重庆大学高端装备机械传动全国重点实验室,重庆,400044

**摘要:**提出了一种基于时间卷积网络-图注意力网络(TCN-GAT)与混合神经网络的烘干系统能耗异常检测方法。首先引入多尺度TCN和多头GAT分别捕获温度、压力等数据的时间特征与空间特征;然后联合反向传播神经网络(BPNN)与变分自编码器(VAE)搭建异常检测模型;再次基于预测误差与重构概率构建能耗异常指标,并引入超阈值模型(POT)拟合Pareto分布建立异常阈值;最后在重庆某汽车工厂涂装车间开展案例验证,利用物联网设备(IoT)采集烘干系统能耗等数据,通过数据分析验证了所提方法的有效性和优越性。

**关键词:**烘干系统;时空特征提取;能耗异常检测;能耗异常指标

**中图分类号:**TP18

**DOI:**10.3969/j.issn.1004-132X.2025.08.021

**开放科学(资源服务)标识码(OSID):**



## Energy Consumption Anomaly Detection of Automobile Painting Drying System Based on TCN-GAT and Hybrid Neural Network

LI Congbo ZHAI Hewang WU Wei\* DONG Ke ZHANG Xiangfei

State Key Laboratory of Mechanical Transmission for Advanced Equipment, Chongqing, 400044

**Abstract:** A method was proposed based on TCN-GAT and hybrid neural networks for identifying anomalies in energy usage for drying systems. First, a multi-scale temporal convolutional network (TCN) and a multi-head graph attention network (GAT) were introduced to capture the temporal and spatial properties of temperature, pressure, and other variables, respectively. An anomaly detection model was built upon a combination of back propagation neural network (BPNN) and variational autoencoder (VAE). Furthermore, an energy consumption anomaly index was formulated based on prediction errors and reconstruction probability. The peak over threshold (POT) model was utilized to fit the Pareto distribution and establish an anomaly threshold. Finally, a case study was carried out at the painting workshop of a Chongqing automobile manufacturer, where Internet of Things (IoT) devices were used to gather real-world data. Data analysis was implemented to verify the effectiveness and superiority of the proposed method.

**Key words:** drying system; spatio-temporal feature extraction; energy consumption anomaly detection; energy consumption anomaly index

### 0 引言

降低汽车制造过程能耗已成为汽车制造业可持续发展的关键战略<sup>[1]</sup>。涂装在汽车制造过程中耗能最大,烘干系统作为其关键组成,能耗占比高达30%<sup>[2]</sup>,且系统长期处于高温高压的工作环境,设备、管路易发生劣化导致生产异常,造成能源浪费<sup>[3]</sup>。能耗作为烘干系统实际运行状态最直接、最真实的反映,对其开展异常检测可以辅助判断车身烘干过程存在的问题,也可作为实施节能改

造的基础,对减少汽车制造过程无效用能、降低事故发生风险具有重要意义。

当前,能耗异常检测受到学者们的广泛关注。相比依靠专家经验设置固定阈值<sup>[4]</sup>,更多研究者通过算法来判断系统能耗异常问题。SIMMINI等<sup>[5]</sup>提出一种自校正核主成分分析(kernel principal component analysis, KPCA)异常检测方法,基于正常数据训练模型,以平方预测误差(squared prediction error, SPE)实现制冷机系统的能耗异常检测。YIN等<sup>[6]</sup>为检测挤压机能耗异常,提出一种基于雨流的连通性异常因子算法,并设置动态阈值识别异常能耗。JIN等<sup>[7]</sup>考虑钢铁生产过程的能耗数据特征和制造过程信号,提出一种变尺度超立方加速密度空间聚类异常检测方法,模

收稿日期:2024-02-27

基金项目:国家自然科学基金(92367107);中央高校基本科研业务  
费专项资金(2023CDJYXTD-003);中国博士后科学基金  
(2023M730406)

型的F1-score达到96.81%。此外,高耗能系统如区域供暖系统<sup>[8]</sup>、城轨牵引系统<sup>[9]</sup>也是学者们开展能耗异常检测的对象。综上所述,能耗异常检测已在多种场景下开展,但针对汽车涂装烘干系统能耗异常检测的研究尚不充分,为降低汽车制造过程能源浪费与事故发生风险,对汽车制造涂装工艺下烘干系统开展能耗异常检测研究具有一定的实践价值。

深度学习作为一种端到端的算法,在异常检测领域展现出良好的效果。基于深度学习的异常检测一般可分为基于预测和基于重构的方法。基于预测的异常检测是通过历史数据建立预测模型,根据预测值和实际值的残差来判别异常。如HUNDMAN等<sup>[10]</sup>基于航天器遥测数据利用长短时记忆网络(long short-term memory, LSTM)建立预测模型,通过预测误差检测异常。DING等<sup>[11]</sup>提出一种结合层次时间记忆和贝叶斯网络的异常检测算法,以检测云平台系统中的异常行为。CHEN等<sup>[12]</sup>将Gumbel-Softmax采样技巧与Transformer结合,建立了基于图学习的异常检测模型。基于重构的方法则是学习正常模式下的数据分布,当异常数据输入模型时,重构结果会与原始数据存在较大差异。如ZHAO等<sup>[13]</sup>使用DAE(deep auto-encoder)进行风力涡轮机的异常检测,将重构误差作为异常分数,成功识别风力涡轮机的温度异常。ZHANG等<sup>[14]</sup>集成变分自编码器(variational auto-encoders, VAE)和Transformer,利用传感器数据完成了对工业设备的异常检测。SONG等<sup>[15]</sup>设计了包含多个鉴别器的生成对抗网络(generative adversarial networks, GAN),利用能耗数据实现了机器人的健康状态检测。上述方法中,预测方法善于处理时序数据,但对异常数据较

少的样本难以捕获其中的异常特征。重构方法虽然对异常数据较为敏感,但其处理长序列数据的能力较弱,此外,烘干系统运行过程中受车辆进出、环境变化等因素影响,系统能耗等时刻波动,且系统的温度、压力、燃气流量等存在耦合关系,一般方法无法全面获取其中的隐藏信息。

为解决上述问题,本文提出一种基于TCN-GAT与混合神经网络的烘干系统能耗异常检测方法。首先引入时间卷积网络(temporal convolutional network, TCN),在时间维度上捕捉温度等时序数据的依赖关系,通过图注意力网络(graph attention networks, GAT)自适应学习不同数据的关系权重,挖掘其空间特征,实现数据信息的深层次挖掘;然后兼顾预测方法序列建模的优势与重构方法对异常数据识别的敏感性,联合反向传播神经网络(back propagation neural network, BPNN)和VAE构建能耗异常检测模型;再次引入超阈值模型(peak over threshold, POT),通过拟合Pareto分布建立能耗异常指标的动态阈值;最后将超过阈值的数据标记为异常,从而实现烘干系统能耗的异常检测。

### 1 问题描述与方法框架

#### 1.1 问题描述

汽车涂装所使用的烘干系统一般由烘干室、燃烧器、热交换器、风机等设备组成,系统结构如图1所示。车身烘干过程中,天然气与压缩空气一同被送入燃烧器燃烧,产生的高温气体被送入热交换器进行热量交换,随即输出高温空气至烘干室,与车身换热后气体的温度降低,由风机送回至热交换器重新加热成为高温空气,由此实现车身的循环供热。系统运行过程中热交换器管路内

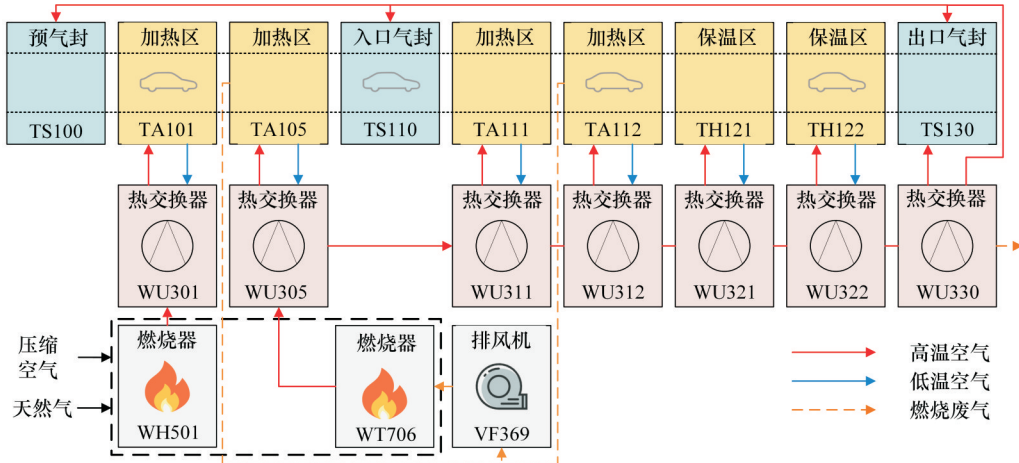


图1 汽车涂装烘干系统结构

Fig.1 Drying system structure of automobile painting

部会不断积聚沉淀物影响传热,风机长期运行会发生转子磨损、不平衡等故障而停机,此外空气中的杂质也会堵塞燃气输送管道,以上情况都会使烘干系统能耗出现异常。本文基于烘干系统天然气流量、热交换器的出口温度、压力等数据,挖掘其中的时空特征,建立能耗异常检测模型,实现系统运行过程能耗的异常检测。

### 1.2 烘干系统能耗异常检测框架

为准确判断烘干系统能耗是否异常,提出一种基于TCN-GAT与混合神经网络的烘干系统能耗异常检测方法,如图2所示,包括烘干系统数据采集、数据预处理与特征提取、烘干系统能耗异常检测。具体内容如下:

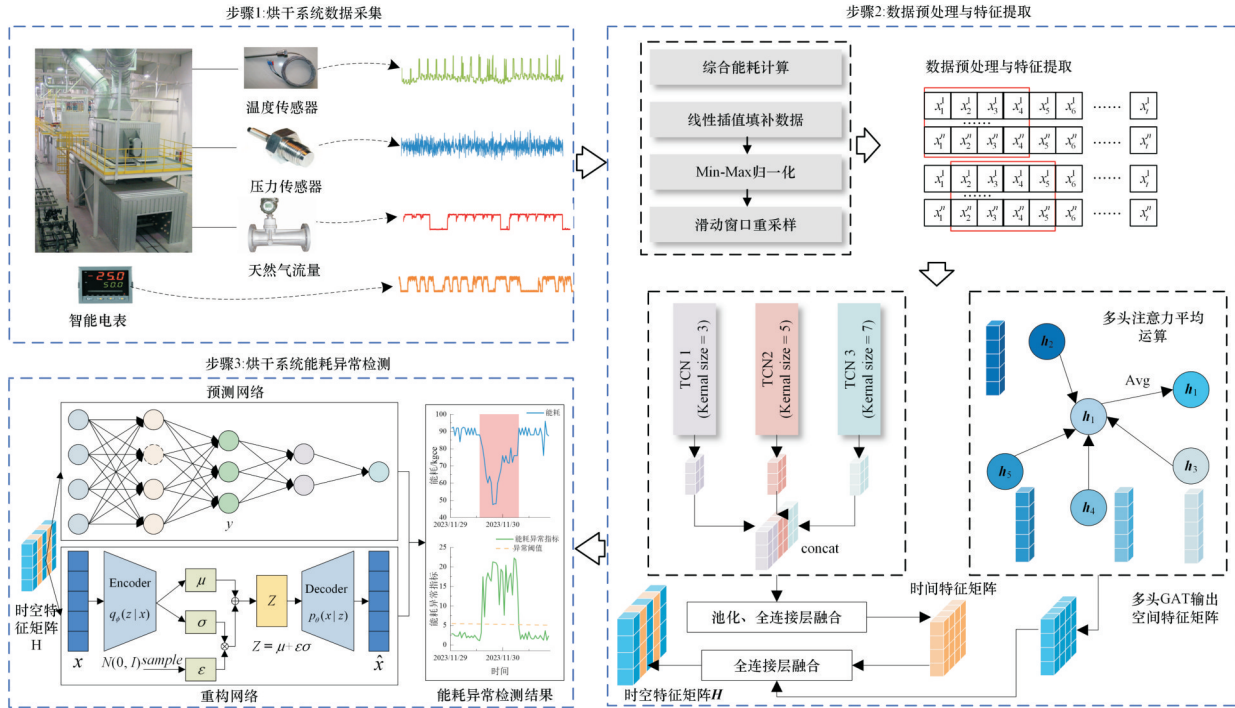


图2 烘干系统能耗异常检测方法框架

Fig.2 The framework of energy consumption anomaly detection method for drying system

1)烘干系统数据采集。使用温度、压力、流量等传感器以及智能电表对烘干系统相关数据进行采集,为开展烘干系统能耗异常检测提供数据支撑。

2)数据预处理与特征提取。采用综合能耗计算方法对能耗数据进行折算。此外,由于网络连接不稳定等情况,采集数据存在缺失,故采用线性插值法进行填补,利用归一化消除数据量纲的差异,然后通过滑动窗口实现数据重采样;引入多尺度TCN和多头GAT分别提取烘干系统数据的时间与空间特征,并将其输入全连接层进行融合,获得表征系统状态的时空特征矩阵。

3)烘干系统能耗异常检测。构建基于误差反向传播(back propagation, BP)神经网络和VAE网络的异常检测模型,将烘干系统时空特征输入模型,输出能耗异常指标,由POT确定异常阈值,指标超过阈值即判定为能耗异常。

### 2 烘干系统数据预处理与特征提取

烘干系统结构复杂、设备众多,采集过程中存

在网络中断等问题,导致数据体量大、维度高、质量差,若直接使用,不仅影响模型训练的速度和效果,还会忽视温度、压力等数据的时序依赖关系和空间依赖特性,致使其中隐藏的异常信息不能被充分挖掘,因此,需对采集的数据进行预处理与特征提取,提高异常检测的精度。

#### 2.1 数据预处理

1)烘干系统中涉及电能、天然气,对于两种不同的能源,按照《综合能耗计算通则》统一折算为标准煤:

$$E = \sum_{i=1}^n (E_i k_i) \quad (1)$$

式中: $E$ 为综合能耗,kgce; $n$ 为消耗能源的种类; $E_i$ 为实际消耗的第*i*种能源量; $k_i$ 为第*i*种能源的折标煤系数,其中,电能的折标煤系数为0.1229 kgce/(kW·h),天然气的折标煤系数为1.2143 kgce/m<sup>3</sup>。

2)采用线性插值的方法填补数据,假设 $t_i$ 时刻的数据 $x_i$ 缺失,与其相邻的 $t_p$ 和 $t_q$ 时刻数据为 $x_p$ 和 $x_q$ ,经过线性插值后的估计值为

$$\hat{x}_i = x_p + \frac{x_q - x_p}{t_q - t_p} (t_i - t_p) \quad (2)$$

3) 使用 Min-Max 归一化方法对数据进行处  
理,将其缩放到0~1之间的数值。归一化变量为

$$x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

式中: $x_{\max}$ 为归一化前变量的最大值; $x_{\min}$ 为归一化前变量的最小值。

假设烘干系统运行过程共采集了  $n$  个参数,其序列为  $X = [X^{(1)} X^{(2)} \dots X^{(l)} \dots X^{(n)}]$ ,第  $l$  个参数数据为  $X = [X_1^{(1)} X_2^{(2)} \dots X_t^{(l)} \dots X_m^{(n)}]$ ,  $m$  表示采集数据的总长度, $t$ 表示参数的第  $t$  个时间点,得到的数据形式为

$$X = \begin{bmatrix} x_1^{(1)} & x_1^{(2)} & \dots & x_1^{(n)} \\ x_2^{(1)} & x_2^{(2)} & \dots & x_2^{(n)} \\ \vdots & \vdots & \dots & \vdots \\ x_m^{(1)} & x_m^{(2)} & \dots & x_m^{(n)} \end{bmatrix} \in \mathbb{R}^{m \times n} \quad (4)$$

4)为使模型充分学习数据上下文信息,实现对未来信息的“记忆”,使用窗口宽度为  $w$  的滑动

时窗,每次移动一个时间点对原始数据进行处理,使得每个样本包含  $w$  个时间点数据,处理后的数据为

$$S_p = \{x_k^1, x_{k+1}^1, \dots, x_{k+w-1}^1; x_k^2, x_{k+1}^2, \dots, x_{k+w-1}^2; \dots; x_k^n, x_{k+1}^n, \dots, x_{k+w-1}^n\} \quad (5)$$

$$k = 1, 2, \dots, k - w + 1$$

## 2.2 基于TCN-GAT的烘干系统数据时空特征提取

烘干系统每日按照既定模式运行,采集的数据整体呈周期性与趋势性,对于温度等缓变量,当前时刻值与前一时刻密切相关,存在时间依赖性特征;此外,采集数据的传感器分散于系统各处,彼此存在物理空间位置关系,不同采集点的温度、压力相互耦合。为充分挖掘数据的内部信息,本文引入TCN与多头GAT提取烘干系统数据的时间与空间特征,具体过程如图3所示。

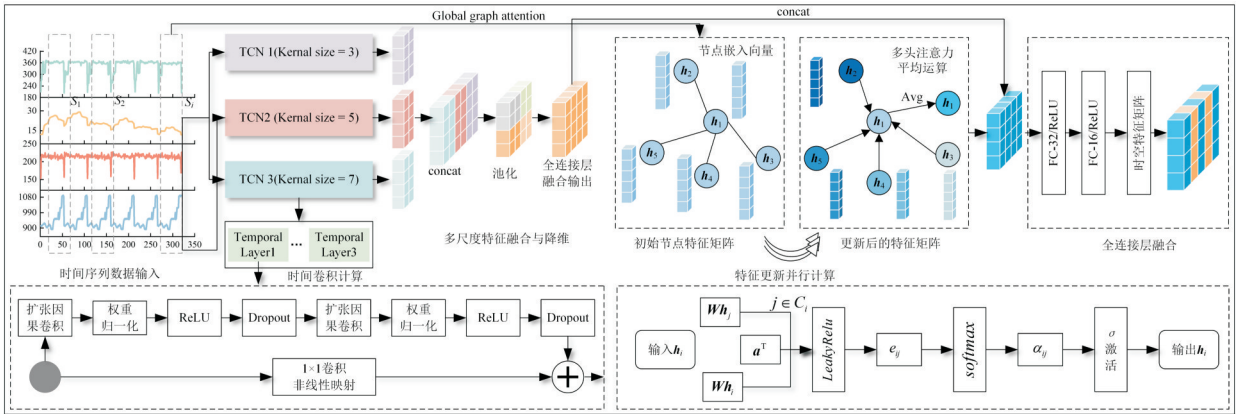


图3 烘干系统数据时空特征提取过程

Fig.3 Spatio-temporal feature extraction process of drying system

1)时间特征提取。本文设计多个具有不同大小滤波器的TCN,对采集数据进行时间特征提取。每个TCN包含三层时间卷积模块,每一层都由两个扩张因果卷积与权重归一化组成,并经过ReLU激活函数输出结果。TCN扩张因果卷积的计算公式为

$$F(t) = \sum_{i=0}^{k-1} f(i) x_{t-di} \quad (6)$$

其中, $F(t)$ 表示  $t$  时刻元素的卷积结果; $f(i)$ 为卷积核; $k$ 是卷积核的大小; $d$ 是膨胀因子。TCN通过残差连接将上层的结果传递至下层:

$$y_n = F(t) + \sum_{i=1}^{n-1} R(t_i, F_i) \quad (7)$$

式中: $y_n$ 为每层TCN提取到的时间特征; $F$ 为扩张卷积操作; $R$ 为跨层残差连接。

假设输入网络的序列为  $x = \{x_1, x_2, \dots, x_{t-1}, x_t\}$ ,则通过三层TCN网络提取到的时间特征为

$$h_t = \{y_1, y_2, \dots, y_{t-1}, y_t\} \quad (8)$$

将每个TCN的结果使用  $concat()$  函数拼接,随后输入池化层、全连接层,获得时间特征矩阵:

$$H_t = FC(Avgpooling(concat(h_t^1, h_t^2, \dots, h_t^c))) \quad (9)$$

式中: $FC$ 为全连接; $Avgpooling$ 为平均池化函数; $c$ 为TCN网络的数量。

2)空间特征提取。数据间的关系可以通过图注意力操作捕获:将烘干系统采集的每种数据视为图的节点,定义  $H = [h_1 h_2 \dots h_n]$ ,  $h_n \in \mathbb{R}^D$  为节点的集合,其中, $n$ 为采集数据的种类, $D$ 为节点向量的特征维度,本文中  $D$  的大小为输入GAT模型的时间戳。在没有先验知识的情况下使用全局注意力模式,节点  $i$  的候选集是除其本身之外的所有节点,定义  $C_i \subseteq \{1, 2, \dots, N\} \setminus \{i\}$ ,“ $\setminus$ ”表示集合  $\{1, 2, \dots, N\}$  中不包含元素  $i$ ,图注意力网络通过下式计算每个节点的输出:

$$h_i = \sigma \left( \sum_{j \in C_i} \alpha_{ij} h_j \right) \quad (10)$$

式中： $\sigma$ 为Sigmoid激活函数； $\alpha_{ij}$ 为衡量节点 $j$ 对节点 $i$ 影响程度的注意力分数。

注意力分数由以下公式计算：

$$e_{ij} = \text{LeakyReLU}(\mathbf{a}^T [\mathbf{W}h_i \parallel \mathbf{W}h_j]) \quad (11)$$

$$\alpha_{ij} = \exp(e_{ij}) / \sum_{k \in C_i} \exp(e_{ik}) \quad (12)$$

式中： $\mathbf{W} \in \mathbf{R}^{D' \times D}$ 为权值矩阵； $D'$ 为输出向量的特征维度； $\mathbf{a}^T \in \mathbf{R}^{2D}$ 为可学习参数的列向量； $\text{LeakyReLU}$ 为激活函数。

为实现良好的特征提取效果，本文结合多头注意力机制添加了多个并行的注意力分数计算过程，最终获得节点 $i$ 的特征矩阵：

$$h_i = \sigma \left( \frac{1}{K} \sum_{k=1}^K \sum_{j \in C_i} \alpha_{ij}^k \mathbf{W}^k h_j \right) \quad (13)$$

式中： $K$ 为注意力机制的头数。

汇总每个节点的计算结果，得到烘干系统数据的空间特征矩阵  $H_s = [h_1 \ h_2 \ \dots \ h_i]$ 。

将获得的时间特征与空间特征输入全连接层进行融合与降维，得到表征烘干系统运行过程能耗信息的时空特征矩阵  $H$ ：

$$H = FC_2(FC_1(H_t, H_s)) \quad (14)$$

### 3 基于混合神经网络的烘干系统能耗异常检测

#### 3.1 烘干系统能耗异常检测模型

本文提出的异常检测模型如图4所示，主要由预测网络和重构网络组成，将提取到的烘干系统时空特征矩阵  $H$  作为模型的输入，基于预测误差和重构概率构建能耗异常指标模型作为模型输出。

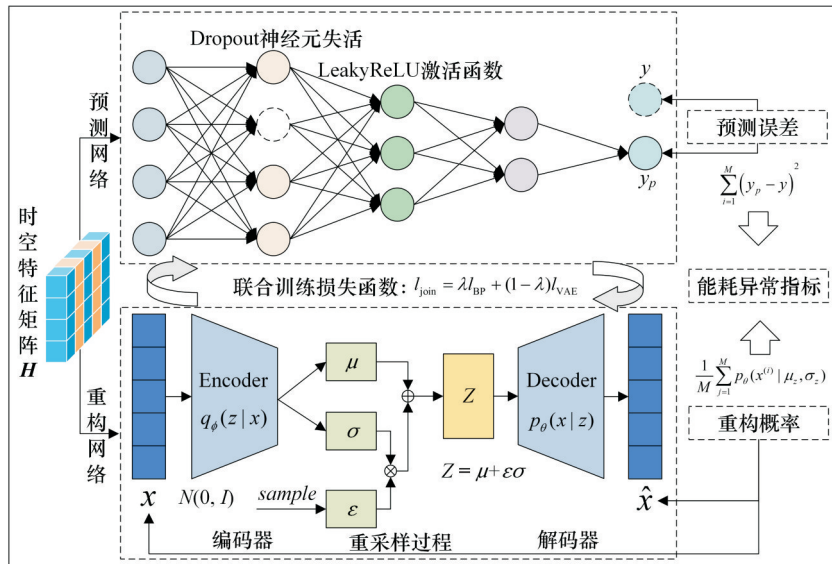


图4 能耗异常检测模型

Fig.4 Energy consumption anomaly detection model

#### 3.1.1 异常检测模型

1)预测网络。采用BP神经网络作为预测网络，用于映射时空特征数据与能耗数据的非线性关系。假设输入网络的数据为 $x$ ，则神经网络每一层的计算过程如下：

$$y_p = f(\mathbf{w}^T x + b) \quad (15)$$

式中： $\mathbf{w}$ 为权重矩阵； $b$ 为偏置； $f$ 为激活函数。

为防止网络发生过拟合，在第一个隐含层加入Dropout机制，此外采用LeakyReLU代替ReLU激活函数，以解决非线性映射后神经元死亡的问题，实现网络的动态变化，加快模型训练的速度。

模型训练完成后，将测试集输入模型即可得到预测值，为实现异常检测，本文将预测值与实际值的残差 $e_p$ 作为预测网络的输出，即

$$e_p = \sum_{i=1}^M (y_p - y)^2 \quad (16)$$

2)重构网络。采用VAE作为检测模型中的重构网络，主要由编码器与解码器两部分组成，本文VAE的编解码器为结构对称的神经网络，设输入的数据为 $x$ ，通过编码器获得潜变量 $z$ ，参数为 $\phi$ ，可表示为分布 $q_\phi(z|x)$ ，潜变量 $z$ 的计算过程如下：

$$z = \mu + \epsilon\sigma \quad (17)$$

式中： $\mu$ 、 $\sigma$ 分别为编码器求解的均值和方差； $\epsilon$ 为根据标准正态分布引入的噪声。

之后，解码器接收潜变量 $z$ ，输出重构数据 $\hat{x}$ ，参数为 $\theta$ ，表示为分布 $p_\theta(\hat{x}|z)$ ， $\hat{x}$ 的最后一维为系统能耗。

当异常能耗数据输入重构网络时，VAE不能

很好地重现原始数据,本文通过计算重构概率<sup>[16]</sup>来衡量数据的重构结果,通过输出每个数据的重构概率,区分能耗的正常与异常,重构概率的计算公式为

$$P_r = \frac{1}{M} \sum_{j=1}^M p_{\theta}(x^{(j)}|\mu_z, \sigma_z) \quad (18)$$

由于机器学习训练时存在数据不确定性,预测模型的输出会受各种因素干扰而产生预测误差,其结果存在着不确定性<sup>[17]</sup>,故本文将能耗异常指标 $S_e$ 定义为预测误差与重构概率的比值:

$$S_e = e_p/P_r \quad (19)$$

当烘干系统出现能耗异常时,预测网络输出较大残差,而重构网络输出较小的重构概率,最终计算得到较大的异常指标值 $S_e$ 。而对于噪声干扰等非异常情况,虽然预测网络也输出较大残差,但重构网络的抗噪能力能够克服此类误差,依然输出较高的重构概率,经过综合计算后,最终获得较小的异常指标值,降低了能耗异常检测误判的风险。

### 3.1.2 模型训练方式

为了结合预测网络与重构网络的优势,并保证模型具有良好的泛化能力,降低预测损失和重构损失潜在的过拟合风险,设计异常检测模型的联合损失函数 $l_{\text{join}}$ 为

$$l_{\text{join}} = \lambda l_{\text{BP}} + (1 - \lambda) l_{\text{VAE}} \quad (20)$$

其中, $\lambda$ 表示损失函数相对权值,用以平衡的网络收敛状态,确保模型在追求高预测精度的同时,维持重构网络对输入数据的抽象学习和对异常模式的敏感捕捉,从而优化整个异常检测模型的泛化性和鲁棒性; $l_{\text{BP}}$ 为BP神经网络的损失函数; $l_{\text{VAE}}$ 为VAE的损失函数,计算公式如下:

$$l_{\text{BP}} = \frac{1}{2N} \sum_{i=1}^N (y - y_p)^2 \quad (21)$$

$$l_{\text{VAE}} = KL(q_{\phi}(z|x) // p_{\theta}(z)) + E_{z \sim q_{\phi}}[\lg p_{\theta}(x|z)] \quad (22)$$

式中: $N$ 为预测样本的数量; $y$ 为烘干系统实际的能耗值; $y_p$ 为预测的能耗值; $KL$ 为散度。

式(22)中,等号右边第一项表示隐变量 $z$ 的近似后验分布 $q_{\phi}(z|x)$ 与先验分布 $p_{\theta}(z)$ 之间的相似程度,通过KL散度进行计算;等号右边第二项表示重构数据与原始数据之间的相似程度,使用最大似然估计求得。

### 3.2 异常判定

本文引入超阈值模型(peak over threshold, POT)<sup>[18]</sup>设定能耗异常指标的阈值,通过比较能耗异常指标值与阈值的大小,将超出阈值的指标值对应能耗确定为异常,而低于或等于阈值的指

标值对应能耗确定为正常。考虑烘干系统存在生产计划调整、环境变化等,以日为时间窗口划分指标序列,计算每日能耗异常指标阈值,过程如下:

将获得的能耗异常指标序列 $S = \{s_1, s_2, \dots, s_T\}$ 划分为长度 $D$ 的子序列 $S_{\text{sub}} = \{s_1, s_2, \dots, s_D\}$ ,在 $S_{\text{sub}}$ 中POT模型认为,超过阈值 $u$ 的部分遵循广义Pareto分布,即

$$\bar{F}(s) = P(S - u > s | S > u) \underset{\mu \rightarrow \tau}{\sim} (1 + \xi s / \beta)^{-1/\beta} \quad (23)$$

式中: $u$ 为初始阈值; $s$ 为序列中的任意值; $S - u$ 为超过阈值 $u$ 的得分序列,经验上设置为高分位数; $\xi, \beta$ 为Pareto分布的参数。

然后通过最大似然估计拟合Pareto分布的参数 $\hat{\xi}$ 和 $\hat{\beta}$ ,求得当日阈值:

$$u_j = u + \frac{\hat{\xi}}{\hat{\beta}} \left( \left( \frac{qn}{N_u} \right)^{\hat{\beta}} - 1 \right) \quad (24)$$

式中: $q$ 为 $s > u$ 的期望概率,即预期异常事件发生的概率; $N_u$ 为超过阈值 $u$ 的数据量。

### 3.3 评价指标

为评估异常检测模型的性能,选取精确率(precision)、召回率(recall)、F1-score作为评价指标,其计算公式略。

## 4 案例分析

为了验证本文方法的有效性与优越性,在重庆某汽车制造企业涂装车间开展案例研究。

### 4.1 实验设定与数据集收集

该汽车企业涂装车间主要生产流程如图5所示,车身需要经过前处理电泳、密封胶喷涂、中涂、色漆及清漆喷涂后才能形成美观和具有保护功能的涂层,而在进行前处理电泳、密封胶以及涂料喷涂后都需要进行烘干固化,以便于后续涂层的喷涂或相关工序的进行。




图5 涂装车间主要工艺流程

Fig.5 The main production process of painting workshop

电泳漆作为车身第一层漆膜,主要提供车身的防腐防锈,若烘干系统发生异常,漆膜会出现烘干不均、橘皮、开裂等问题,不仅会降低其防腐能力,还会影响后续涂层的附着,因此,本文以电泳烘干为例开展能耗异常检测案例研究,电泳烘干的实际场景如图6所示。

通过企业涂装车间部署的能源管理系统、杜



图6 涂装电泳烘干实景

Fig.6 Electrophoretic drying real scene of painting

尔 EcoScreen 设备分析系统以及 EcoEMOS 生产监控系统,分别获得烘干系统功率等能耗数据、温度与压力等监控数据、车辆输送至烘干系统时的过点数据,数据采集过程如图7所示。

基于上述过程,采集的具体数据见表1。采集时间自2023年9月1日至11月30日,数据共计8684条。实验的软件环境为Python 3.9、深度学习框架Pytorch 1.12与CUDA 11.3,硬件配置为Dell Precision 3640、Windows 10系统、CPU Intel Core i9-10900、GPU RTX 2080Ti、内存64 GB。

4.2 数据预处理与特征提取

1)数据预处理。按照式(1)对采集的天然气和电能数据进行综合能耗的计算;对采集的原始数据进行缺失值填补,得到数据集的维度为 $8736 \times 20$ ;然后使用Min-Max归一化数据;设置滑动窗口大小为15,滑动步长为1,对数据进行重采样,最终得到数据集的维度 $8722 \times 15 \times 20$ 。

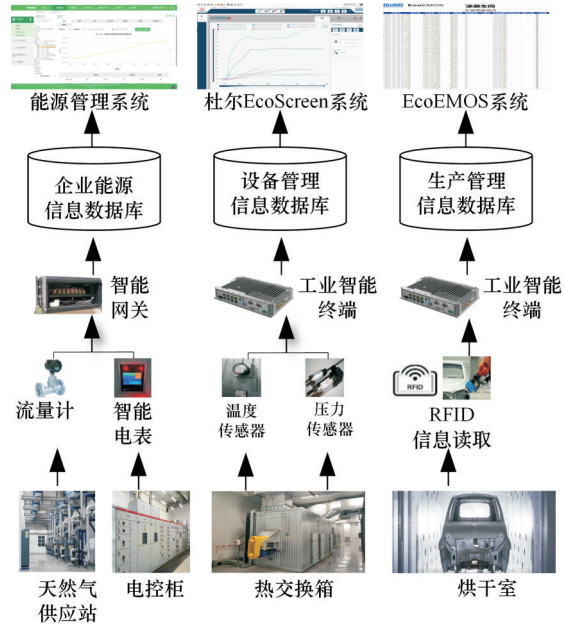


图7 烘干系统数据采集过程

Fig.7 Data acquisition process of drying system

查阅企业的设备动力部巡检日志得知,收集的数据集包含烘干系统运行的异常事件:①11月20日与11月22日,烘干系统加热区WU301的温度未按规定时间达到预设值,系统无法触发保温区的加热模式,能耗曲线发生偏离,其原因为其热交换器劣化发生故障,导致系统总能耗一直处于低值。②11月26日,因燃烧器WT706调节阀阻塞,燃气压力无法稳定,温度控制系统为稳定生产

表1 烘干系统采集参数及部分数据

Tab.1 The collection parameters of drying system

设备型号	采集参数	单位	2023-09-01 00:00	2023-09-01 00:15	...	2023-11-30 23:45
		生产环境温度 $t_0$	℃	28.1633	28.1013	...
P1E1T1WU301	加热区 WU301 热交换箱温度 $t_1$	℃	87.7268	84.3041	...	92.4576
	加热区 WU301 热交换箱压力 $p_1$	Pa	985.7992	941.4691	...	945.8357
P1E1T1WU305	加热区 WU305 热交换箱温度 $t_2$	℃	91.8505	88.0155	...	95.1895
	加热区 WU305 热交换箱压力 $p_2$	Pa	871.3763	827.7887	...	799.8168
P1E1T1WU311	加热区 WU311 热交换箱温度 $t_3$	℃	202.4742	194.2268	...	201.5335
	加热区 WU311 热交换箱压力 $p_3$	Pa	1139.1655	1087.9481	...	1050.1522
P1E1T1WU312	加热区 WU312 热交换箱温度 $t_4$	℃	209.7732	201.1959	...	199.8039
	加热区 WU312 热交换箱压力 $p_4$	Pa	859.7018	901.0312	...	852.8688
P1E1T1WU321	保温区 WU321 热交换箱温度 $t_5$	℃	205.8415	200.3581	...	201.0850
	保温区 WU321 热交换箱压力 $p_5$	Pa	846.2278	841.8042	...	854.8539
P1E1T1WU322	保温区 WU322 热交换箱温度 $t_6$	℃	210.7216	201.6495	...	200.9524
	保温区 WU322 热交换箱压力 $p_6$	Pa	995.0804	950.4124	...	912.7543
P1E1T1WT330	新风换热热交换箱出口温度 $t_7$	℃	192.4147	184.2268	...	167.1398
	新风换热热交换箱出口压力 $p_7$	Pa	1989.4853	1974.5362	...	1946.1635
P1E1T1WT706	天然气流量 $V$	$m^3/h$	206.7545	199.2641	...	198.3837
P1E1T1	烘干系统总电流 $I$	A	695.3133	689.1621	...	230.9267
	烘干系统总功率 $P$	kW	373.1522	166.5457	...	25.2675
	烘干系统产量 $Q$	辆	7	8	...	2
	烘干系统综合能耗 $E$	kgce	92.1247	88.5453	...	36.8854

环境直接增大天然气阀门,造成系统能耗增加,而在11月30日热交换器WU301风机长期运转出现故障停机,系统能耗下降。其中,9月1日至11月15日的数据为正常运行数据,将其设置为训练集;11月16日至11月30日的数据为测试集,按照异常事件将其划分成两个大小相同的数据集,具体信息见表2。

表2 异常检测数据集信息

Tab.2 Anomaly detection dataset information

数据集	正常数据/ 条	数据占比/ %	异常数据/ 条	数据占比/ %
训练集	7378	100	0	0
测试集1	672	97.0	20	3.0
测试集2	672	93.6	43	6.4

2)特征提取。将预处理后的数据输入到TCN-GAT网络进行时间特征和空间特征的提取,并通过全连接层进行融合,TCN、GAT和融合网络的参数设置见表3。

表3 模型超参数设置

Tab.3 Super parameter setting of the model

模型	超参数	数值
TCN	TCN网络数量	3
	时间卷积模块数量	3
	卷积核大小	3,5,7
	隐藏层通道数量	[32,64,32]
时间特征融合网络	平均池化层窗口大小	3×3
	步幅	3
	全连接层	[32,16]
GAT	节点数目	20
	注意力头数	4
	激活函数	LeakyReLU
	节点特征维度	15
融合网络	全连接层	[32, 16, 8]

时空特征提取网络模型训练次数为150,学习率为0.001,正则率为0.2,优化器为Adma,批处理大小为32。三个TCN输出的结果经过池化、全连接层进行融合,输出时间特征为 $H_t = \{h_1, h_2, \dots, h_{16}\}$ ;将数据的20个维度视作图节点输入GAT模型,设置4头注意力并行计算,输出空间特征为 $H_s = [h_1, h_2, \dots, h_{16}]$ ;时间特征 $H_t$ 与空间特征 $H_s$ 输入两层全连接层进行特征融合并降维,最终获得烘干系统时空特征矩阵 $H = [x_1, x_2, \dots, x_8]$ 。

### 4.3 实验结果及对比

#### 4.3.1 实验结果

异常检测模型中BP神经网络设置3个隐藏层,神经元数量依次为32、64、32,输出层设置为1。VAE网络设置潜变量维度为4,重采样的样本

数为10,输出矩阵的维度为8。采用Adma函数更新网络参数,学习率设为0.001,批次大小为32,最大迭代次数为100。将式(20)作为模型的总损失函数, $\lambda$ 取0.7,训练过程损失函数的变化如图8所示。




图8 模型训练结果

Fig.8 The training results of Model

由图8可知,当迭代至536代时,各损失函数逐渐平稳,模型的总损失收敛到0.023,之后损失值大小基本不再变化,训练完成。将包含异常事件的测试集输入到已训练的模型中,得到能耗异常检测结果,如图9、图10所示。

烘干系统正常运行时,从开启至达到设定的工艺温度条件需经历2.5h,且烘干系统每日能耗趋势基本相同,输入异常检测模型计算出的能耗异常指标值小范围波动,但低于POT拟合的阈值;而当系统偏离正常运行状态时,能耗异常指标值的计算结果明显高于阈值。如图9所示,模型在11月20日11时45分、11月22日07时15分计算的能耗异常指标超出了阈值,这表明系统出现了异常,检测结果与巡检日志相一致。

受生产计划的影响,烘干系统连日运行,正常生产过程中系统能耗达到峰值后呈小范围波动,但异常能耗明显区别平均水平。如图10所示,11月26日02时30分、11月27日02时00分、11月30日04时45分模型计算的能耗异常指标均高于当日阈值,由此判定系统出现能耗异常检测问题,检测结果与巡检日志记录相一致。

#### 4.3.2 方法对比分析

为充分验证所提方法的优越性,本文以采集的烘干系统数据为基础,开展鲁棒性实验、对比实验、消融实验,具体内容如下:

1)鲁棒性实验。为了检测模型的鲁棒性,使用训练数据作为变量来测试模型性能,在训练过程中逐渐增加原始训练集的数量(60%,70%,80%,90%,100%),实验结果见表4。由表4可




图9 测试集1异常检测结果

Fig.9 The result of test set 1 anomaly detection

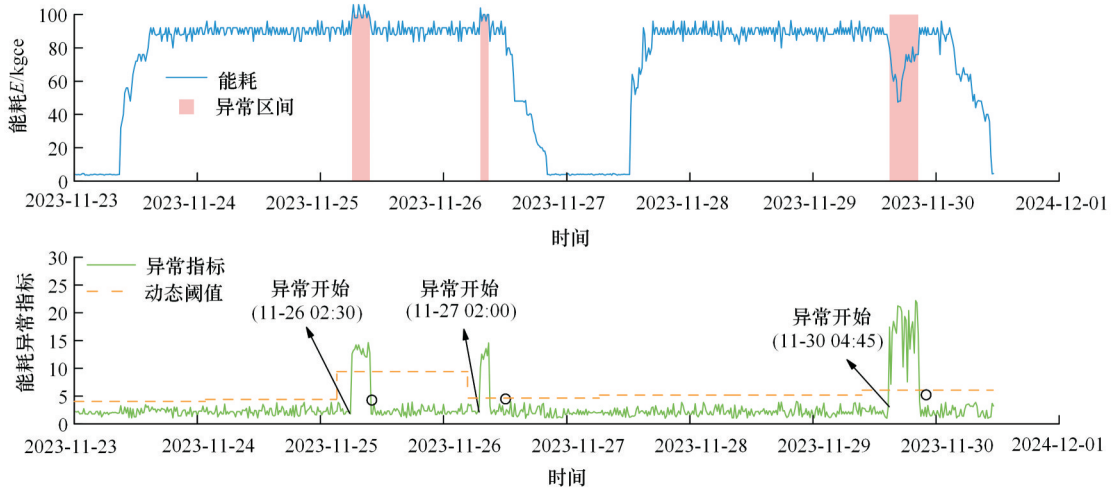


图10 测试集2异常检测结果

Fig.10 The result of test set 2 anomaly detection

表4 不同训练集下异常检测结果

Tab.4 The anomaly detection results of the training set

数据集	训练集占比/%	精确率	召回率	F1-score
测试集1	60	0.8840	0.8910	0.8875
	70	0.8915	0.8961	0.8938
	80	0.9215	0.8984	0.9098
	90	0.9417	0.9242	0.9329
	100	0.9764	0.9522	0.9641
测试集2	60	0.8474	0.8714	0.8592
	70	0.8855	0.8925	0.8890
	80	0.9018	0.9284	0.9149
	90	0.9178	0.9202	0.9190
	100	0.9512	0.9635	0.9573

知,当训练集中的数量下降至60%时,模型仍然保持0.85以上的F1-score,这表明本文的异常检测方法即使在减少部分训练样本的情况下也能保持良好性能。

2)对比实验。为验证本文方法的优越性,与重构方法VAE、GAN、预测方法OC-CNN、

LSTM共4种异常检测模型进行对比,模型的具体参数设置见表5,将烘干系统数据经过特征提取输入各模型中,阈值的选取同样使用POT模型,实验结果见表6。由表6可知,本文模型的精确率、召回率和F1-score各评价指标在测试集1的表现均优于VAE、GAN、OC-CNN和LSTM,

表5 算法超参数设置

Tab.5 The algorithm hyperparameter settings

超参数	模型			
	VAE	GAN	OC-CNN	LSTM
网络层数	3(编码器) 3(解码器)	3(生成器) 2(判别器)	4(卷积层)	4(LSTM)
学习率	0.001	0.001	0.001	0.001
迭代次数	800	800	800	800
批次大小	32	32	32	32
输入维度	9	9	8	8
输出维度	9	9	1	1
激活函数	Tanh	ReLU	ReLU	ReLU
隐藏层大小	32,64,32	32,64,32	32,64,32	32,64,32

表6 算法对比实验结果

Tab.6 The algorithm comparison results

数据集	模型	指标		
		精确率	召回率	F1-score
测试集1	VAE	0.9012	0.9133	0.9072
	GAN	0.8807	0.8835	0.8821
	OC-CNN	0.9415	0.9338	0.9376
	LSTM	0.9248	0.9214	0.9231
	本文模型	<b>0.9764</b>	<b>0.9522</b>	<b>0.9641</b>
测试集2	VAE	0.8998	0.9024	0.9011
	GAN	0.8798	0.8994	0.8895
	OC-CNN	<b>0.9608</b>	0.9211	0.9405
	LSTM	0.9555	0.8791	0.9157
	本文模型	0.9512	<b>0.9635</b>	<b>0.9573</b>

而在测试集2上,尽管OC-CNN取得了最高的精确率,但其召回率指标均劣于本文模型,在烘干系统能耗异常检测中,漏检后果相比误判更为严重,同时,对比F1-score可知,本文模型有更好的预防漏检和误判能力。

3)消融实验。为了证明所提模型各关键模块的有效性,设计了一系列消融实验,模型的各种变体如下:V1模型,移除多尺度TCN时间特征提取模块;V2模型,移除多头GAT空间特征提取模块;V3模型,将时间特征和空间特征提取模块移除;V4模型,异常检测只使用BP神经网络;V5模型,异常检测只使用VAE网络。消融实验结果见表7。可知,当异常检测结合时空特征提取的方法后,模型的F1-score在两个测试集上分别提高18.24%、17.41%,结果表明,挖掘数据的时空特征对提升模型的检测精度是有效的;使用V4和V5模型进行检测时各项指标下降,表明联合预测网络和重构网络进行异常检测,并将结果进行融合,检测效果会更好。

表7 消融实验结果

Tab.7 The result of ablation experiment

数据集	模型	精确率	召回率	F1-score
测试集1	V1	0.8741	0.8978	0.8858
	V2	0.8638	0.8676	0.8657
	V3	0.8447	0.7880	0.8154
	V4	0.9407	0.9231	0.9318
	V5	0.9211	0.9243	0.9227
	本文模型	<b>0.9764</b>	<b>0.9522</b>	<b>0.9641</b>
测试集2	V1	0.8467	0.8147	0.8304
	V2	0.8517	0.8452	0.8484
	V3	0.8348	0.7967	0.8153
	V4	0.9350	0.9274	0.9312
	V5	0.9167	0.9434	0.9299
	本文模型	<b>0.9512</b>	<b>0.9635</b>	<b>0.9573</b>

## 5 结论

1)本文提出了一种基于TCN-GAT的时空特征提取方法,通过引入多尺度TCN和多头GAT,并结合全连接层融合网络,挖掘了烘干系统多维数据周期性、关联性等特征,实现了数据时间特征与空间特征的捕捉,对发现数据中隐藏模式和异常信息、提高异常检测的精度具有积极作用。

2)搭建了一种基于BP神经网络和VAE的混合神经网络,结合POT模型实现了烘干系统能耗异常检测。通过结合网络的输出构建能耗异常指标,并设计联合训练损失函数,实现了预测网络和重构网络的优势互补,同时基于极值理论POT模型确定指标阈值,使得阈值设定更为合理,由此取得了良好的异常检测效果。

3)在案例验证部分,基于采集的重庆某汽车企业涂装车间烘干系统实际数据,将本文方法与VAE、GAN、OC-CNN、LSTM进行对比,结果表明本文方法的在两个测试集上的F1-score均优于其他算法;此外,通过开展鲁棒性实验证明了所提方法在减少部分训练样本时依然能保持良好性能,说明模型在数据量较少的场景下依然有着实用性;通过消融实验证明了时空特征提取以及重构预测相结合的方法可有效提高模型的性能,进一步证明了所提方法的有效性和优越性。

### 参考文献:

[1] ZHAO Fuquan, LIU Xinglong, ZHANG Haoyi, et al. Automobile Industry under China's Carbon Peaking and Carbon Neutrality Goals: Challenges, Opportunities, and Coping Strategies[J]. Journal of Advanced Transportation, 2022, 2022(1): 5834707.

[2] GIAMPIERI A, MA Zhiwei, LING-CHIN J, et al. A Techno-economic Evaluation of Low-grade Excess Heat Recovery and Liquid Desiccant-based Temperature and Humidity Control in Automotive Paint Shops[J]. Energy Conversion and Management, 2022, 261: 115654.

[3] GIAMPIERI A, LING-CHIN J, MA Z, et al. A Review of the Current Automotive Manufacturing Practice from an Energy Perspective[J]. Applied Energy, 2020, 261: 114074.

[4] PANG Guansong, SHEN Chunhua, CAO Longbing, et al. Deep Learning for Anomaly Detection: a Review[J]. ACM Computing Surveys, 2021, 54(2): 1-38.

- [5] SIMMINI F, RAMPAZZO M, PETERLE F, et al. A Self-tuning KPCA-based Approach to Fault Detection in Chiller Systems[J]. IEEE Transactions on Control Systems Technology, 2022, 30(4): 1359-1374.
- [6] YIN Sihua, YANG Haidong, XU Kangkang, et al. Dynamic Real-time Abnormal Energy Consumption Detection and Energy Efficiency Optimization Analysis Considering Uncertainty [J]. Applied Energy, 2022, 307: 118314.
- [7] JIN Feng, WU Hao, LIU Yang, et al. Varying-scale HCA-DBSCAN-based Anomaly Detection Method for Multi-dimensional Energy Data in Steel Industry [J]. Information Sciences, 2023, 647: 119479.
- [8] SØNDERGAARD H A N, SHAKER H R, JØRGENSEN B N. Automated and Real-time Anomaly Indexing for District Heating Maintenance Decision Support System[J]. Applied Thermal Engineering, 2023, 233: 120964.
- [9] 李熙, 张立成. 针对时间序列的城轨牵引能耗异常分析[J]. 北京交通大学学报, 2021, 45(5): 30-36. LI Xi, ZHANG Licheng. Outlier Analysis of Urban Rail Traction Energy Consumption Based on Time Series [J]. Journal of Beijing Jiaotong University, 2021, 45(5): 30-36.
- [10] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting Spacecraft Anomalies Using LSTMS and Nonparametric Dynamic Thresholding [C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, 2018: 387-395.
- [11] DING Nan, GAO Huanbo, BU Hongyu, et al. RADM: Real-time Anomaly Detection in Multivariate Time Series Based on Bayesian Network [C] // 2018 IEEE International Conference on Smart Internet of Things (SmartIoT). Xi'an, 2018: 129-134.
- [12] CHEN Zekai, CHEN Dingshuo, ZHANG Xiao, et al. Learning Graph Structures with Transformer for Multivariate Time-series Anomaly Detection in IoT [J]. IEEE Internet of Things Journal, 2022, 9(12): 9179-9189.
- [13] ZHAO Hongshan, LIU Huihai, HU Wenjing, et al. Anomaly Detection and Fault Analysis of Wind Turbine Components Based on Deep Learning Network [J]. Renewable Energy, 2018, 127: 825-834.
- [14] ZHANG Hongwei, XIA Yuanqing, YAN Tijin, et al. Unsupervised Anomaly Detection in Multivariate Time Series through Transformer-based Variational Autoencoder [C] // 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming, 2021: 281-286.
- [15] SONG Ge, HONG S H, KYZER T, et al. Energy Consumption Auditing Based on a Generative Adversarial Network for Anomaly Detection of Robotic Manipulators [J]. Future Generation Computer Systems, 2023, 149: 376-389.
- [16] LINANDER H, BALABANOV O, YANG H, et al. Looking at the Posterior: Accuracy and Uncertainty of Neural-network Predictions [J]. Machine Learning: Science and Technology, 2023, 4(4): 045032.
- [17] IQBAL T, QURESHI S. Reconstruction Probability-based Anomaly Detection Using Variational Auto-encoders [J]. International Journal of Computers and Applications, 2023, 45(3): 231-237.
- [18] SUN Changcheng, HE Zhiwei, LIN Huipin, et al. Anomaly Detection of Power Battery Pack Using Gated Recurrent Units Based Variational Autoencoder [J]. Applied Soft Computing, 2023, 132: 109903.

(编辑 陈勇)

**作者简介:** 李聪波,男,1981年生,教授、博士研究生导师。研究方向为绿色制造与智能制造。E-mail: congboli@cqu.edu.cn。  
吴畏(通信作者),男,1995年生,助理研究员、博士后研究人员。研究方向为工业物联网、工业人工智能、智能制造。E-mail: bravew@cqu.edu.cn。

**本文引用格式:**

李聪波, 翟贺旺, 吴畏, 等. 基于TCN-GAT与混合神经网络的汽车涂装烘干系统能耗异常检测[J]. 中国机械工程, 2025, 36(8): 1864-1874.

LI Congbo, ZHAI Hewang, WU Wei, et al. Energy Consumption Anomaly Detection of Automobile Painting Drying System Based on TCN-GAT and Hybrid Neural Network [J]. China Mechanical Engineering, 2025, 36(8): 1864-1874.