

DOI: 10.19783/j.cnki.pspc.250805

# 融合参考值与改进生成对抗网络的台区负荷数据修复方法

王小龙, 蔡昊天, 张浩博, 彭庆炯, 彭显刚, 赵卓立

(广东工业大学自动化学院, 广东 广州 510006)

**摘要:** 传统数据修复方法因忽略外部时空关联信息导致台区负荷修复精度受限。提出一种融合参考值与改进生成对抗网络的台区负荷数据修复方法。首先, 提出一种参考值构建方法, 将外部信息与负荷自身时空关联融合, 生成逼近真实数据分布的修复起点。其次, 在生成对抗网络结构中设计动态位置编码替代随机噪声, 获取缺失数据上下文信息。接着嵌入混合残差空洞卷积及通道注意力机制, 以增强模型负荷波动特征提取能力。再将多尺度结构相似性损失引入原始损失函数以优化训练效果。最后, 基于实测数据验证, 所提方法相较于传统数据修复方法修复精度提高约40%。

**关键词:** 低压台区; 数据修复; 参考值; 生成对抗网络; 动态位置编码

## Load data restoration method for distribution transformer areas based on reference values and an improved generative adversarial network

WANG Xiaolong, CAI Haotian, ZHANG Haobo, PENG Qingjiong, PENG Xiangang, ZHAO Zhuoli

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

**Abstract:** Traditional data restoration methods are limited in accuracy for distribution transformer area load data because they neglect external spatiotemporal correlations. This paper proposes a load data restoration method that combines reference values and an improved generative adversarial network (GAN). First, a reference value construction method is developed, which integrates external information with the load's own spatiotemporal correlations to generate an initial restoration point that approximates the true data distribution. Then, within the GAN structure, dynamic positional encoding is designed to replace random noise, enabling the model to capture contextual information of missing data. Hybrid residual dilated convolutions and a channel attention mechanisms are embedded to enhance the model's capability in extracting load fluctuation features. In addition, a multi-scale structural similarity loss is introduced into the original loss function to optimize the training performance. Finally, validation based on real measured data shows that the proposed method improves restoration accuracy by approximately 40% compared to traditional data restoration methods.

This work is supported by the National Natural Science Foundation of China (No. 62273104).

**Key words:** low-voltage distribution transformer area; data restoration; referenced value; generative adversarial network; dynamic positional encoding

## 0 引言

随着智能电网建设的不断推进, 用电信息采集设备的广泛部署, 使得原本分散、孤立的电网基础数据实现大规模集中采集, 为台区层面的大数据应用奠定了坚实基础<sup>[1-4]</sup>。

然而, 在台区负荷数据实际采集过程中, 由于地区通信网络覆盖不均、终端设备维护难度大, 以

及采集频次差异化等原因, 往往出现台区负荷数据断裂或丢失的现象。这不仅降低了台区负荷预测和调度决策的精度, 也限制了电网规划的合理性<sup>[5]</sup>。此外, 台区负荷数据具有高复杂度和强波动性, 这使得仅依赖单纯数学模型难以准确描述其动态变化, 给缺失数据的修复带来了挑战。

数据修复旨在利用现有信息对缺失或不完整数据进行推断与重构<sup>[6]</sup>。最简便的删除法<sup>[7]</sup>虽然操作快捷, 却易丢失关键信息或破坏数据分布, 削弱后续分析效果。统计填充方法<sup>[8-9]</sup>虽然能在一定程度上保持整体结构, 却往往忽略台区负荷数据的相关

**基金项目:** 国家自然科学基金项目资助(62273104); 广东电网有限责任公司科技项目资助(GDKJXM20231545)

性与时序特征, 导致误差较大。为提升数据修复精度, 研究者引入了 K 近邻等自动化算法<sup>[10-12]</sup>, 但这些传统方法在捕捉台区负荷数据长距离依赖和非线性关联方面仍存不足。

近年来, 大量学者采用深度学习修复缺失数据, 如生成对抗网络<sup>[13-16]</sup>(generative adversarial networks, GAN)、残差 U 型网络<sup>[17]</sup>(residual U-Net, RU-Net)、神经网络<sup>[18-19]</sup>(neural network, NN)等。其中, GAN 通过学习样本数据的分布特征来生成新数据, 不依赖传统统计模型和先验假设, 在负荷数据修复领域获得了广泛应用。文献[20]为判别器额外设计提示机制, 使其能够尽可能地利用未缺失信息, 潜在地拟合原始数据的分布特征。文献[21]将对抗生成神经网络与双重语义感知重构约束结合, 使该方法无需先验知识的分布假设与显式物理建模。文献[22]在 Wasserstein 散度生成对抗网络基础上优化生成器的噪声输入, 并采用纵横交叉算法催化粒子群算法优化超参数寻优问题。上述研究多集中于模型自身结构的改进, 而对负荷数据的外部时空关联信息挖掘不足, 未能充分利用其在缺失值修复中的价值。

为挖掘对修复台区负荷数据有实际意义的特征来提高修复精度, 提出一种融合参考值与改进生成对抗网络的台区负荷数据修复方法。首先, 提出一种参考值构建方法, 生成逼近真实数据分布的修复起点, 将数据重构问题从随机噪声生成转化为对已知分布的波形精细化修正。然后, 改进原始生成对抗网络结构: 设置动态位置编码获取缺失上下文信息; 嵌入融合混合残差空洞卷积与通道注意力机制的多尺度时空感知模块, 增强对复杂负荷波动特征的提取; 在损失函数中引入多尺度结构相似性损失, 优化训练过程并提升修复结果的结构一致性。最后, 基于真实台区负荷数据验证所提方法的有效性。

## 1 参考值构建方法

基于台区负荷自相关性和时空关联性, 本文设计参考值构建方法, 为缺失数据修复提供高置信度的负荷修复参考值。其核心机理在于: 通过采用分段三次埃尔米特插值法<sup>[23]</sup>(piecewise cubic Hermite interpolating polynomial, PCHIP)、基于密度扩展的层次聚类<sup>[24]</sup>(hierarchical density-based spatial clustering of applications with noise, HDBSCAN)与动态时序边界约束机制结合的迭代聚类方法, 将外部信息与负荷自身时空关联特征融合, 得到与负荷序列同维度的参考值序列将生成器的输入从传统 GAN 中的随机噪声转换为具有明确物理意义和时空关联的初始分布。参考值构建方法具体步骤如下。

### 1) 构建基础负荷序列。

采用 PCHIP 构建基础负荷序列, 保证各点的连续性和平滑性。

设定已知负荷序列为  $\{\widehat{t}_i, \widehat{x}_i\}$ , 其中  $\widehat{t}_i$  为第  $i$  个采样点,  $\widehat{x}_i$  表示该时刻对应的负荷值。对每一个区间  $[\widehat{t}_i, \widehat{t}_{i+1}]$  上构造三次 Hermite 插值多项式, 如式(1)一式(3)所示。

$$\overline{x}(\widehat{t}) = \widehat{x}_i H_0(\tau) + \widehat{x}_{i+1} H_1(\tau) + h_i d_i H_2(\tau) + h_i d_{i+1} H_3(\tau) \quad (1)$$

$$\tau = \frac{\widehat{t} - \widehat{t}_i}{h_i}, \tau \in [0, 1] \quad (2)$$

$$\begin{cases} H_0(\tau) = 2\tau^3 - 3\tau^2 + 1 \\ H_1(\tau) = -2\tau^3 + 3\tau^2 \\ H_2(\tau) = \tau^3 - 2\tau^2 + \tau \\ H_3(\tau) = \tau^3 - \tau^2 \end{cases} \quad (3)$$

式中:  $\overline{x}(\widehat{t})$  为  $\widehat{t}$  时刻插值负荷值;  $h_i$  为缺失区间长度;  $d_i$  为  $\widehat{x}_i$  的导数估计;  $\widehat{t}$  为负荷值缺失时刻。

对于  $d_i$  的估算有以下规则: 如果第  $i$  个节点附近的差商符号相反, 或者其中一个为 0, 则该点  $d_i$  等于 0; 如果第  $i$  个节点附近的差商符号相同, 则该点  $d_i$  等于左右两个差商的加权平均。

### 2) 提取参考值。

基于负荷的时空关联性和自相关性, 组合日特征、天气特征等外部时空关联信息  $f$  和待修复时间前后  $n$  个时间点的负荷样本构建特征空间  $F$ , 其中负荷样本取自基础负荷序列  $\overline{x}$ 。HDBSCAN 相较于 K-Means 等基于距离的聚类方法, 无需预先指定簇数量, 能有效识别任意形状、非球形的簇结构<sup>[24]</sup>, 适合处理融合了多种外部时空因素、分布复杂的台区负荷特征空间<sup>[25]</sup>。本文应用 HDBSCAN 算法将特征空间划分为  $K$  个聚类簇, 在各簇内提取缺失样本最近邻非缺失样本的负荷值作为参考值。

### 3) 采用动态时序边界约束参考值。

直接使用聚类筛选出的参考值, 可能存在异常点、与当前时间窗口不匹配等问题, 导致生成器学习不稳定。因此, 根据台区负荷的自相关性, 本文设计了动态时序边界约束机制。

首先构建日-周双周期参考数据池  $R(t)$ , 如式(4)所示。

$$R(t) = \bigcup_{k=1}^P \{\overline{x}(t \pm kT_d), \overline{x}(t \pm kT_w)\} \quad (4)$$

式中:  $P$  为周期回溯深度, 本文设置为 2;  $t$  为当前时间点;  $k$  为步长;  $T_d$  为日周期长度;  $T_w$  为周周期长度。

定义连续缺失段集合  $S$ ，如式(5)所示。

$$S = \{(t_s, t_e, l) | m(t) = 1, \forall t \in [t_s, t_e], l = t_e - t_s + 1\} \quad (5)$$

式中： $t_s$  和  $t_e$  分别为起始和结束缺失点； $m$  为掩码矩阵； $l$  为缺失长度。

然后，为提高约束效果，对缺失段进行缺失场景判断。设置缺失阈值长度  $l_r$ 。当缺失段长度小于等于  $l_r$  时，如式(8)所示。式(6)中局部权重因子  $\alpha$  值越大，待修复点前后  $n$  个时间点的负荷样本完整度越高，聚类所得参考值可信度越高。

$$x_a = \alpha x_a + (1 - \alpha) \mu_l \quad (6)$$

$$\alpha = \frac{N_l}{N_{lmax}} \quad (7)$$

$$x_c = \text{clip}(x_a, \mu_w - 3\sigma_w, \mu_w + 3\sigma_w) \quad (8)$$

式中： $x_a$  为聚类所得参考值； $\mu_l$  为  $\bar{x}$  局部窗口均值； $N_l$  和  $N_{lmax}$  分别为以  $x_a$  为中心向前和向后各扩展  $k$  步的局部窗口有效值数量和有效值的最大数量； $x_c$  为约束后的参考值； $\mu_w$  和  $\sigma_w$  分别为窗口内  $\bar{x}$  的平均值和标准值。

当缺失段长度大于  $l_r$  时，基于四分位距构建动态边界  $B$ ，将参考值约束在动态边界内，得到约束后的参考值  $x_c$ ，利用负荷的周期性规律。

$$B = [M - 1.5I, M + 1.5I] \quad (9)$$

式中： $M$  为历史周期负荷数据中位数； $I$  为历史周期负荷数据的四分位距。

最后，为消除系统偏差，对参考值进行全局约束，得到参考值  $x_o$ ，如式(10)所示。

$$x_o = \text{clip}(x_c, \mu - 3\sigma, \mu + 3\sigma) \quad (10)$$

式中： $\mu$  和  $\sigma$  分别为  $\bar{x}$  的平均值和标准值。

4) 将参考值  $x_o$  与特征空间  $F$  组合，作为新的特征空间。

5) 重复多轮步骤 2) 一步骤 4)。计算参考值和真实负荷的误差，若误差收敛，则获得最优参考值  $x_o$ 。

参考值构建流程如图 1 所示。

## 2 基于改进 GAN 的负荷数据修复模型

GAN 的本质是一种通过生成器和判别器进行对抗学习，达到还原数据特征的生成式深度学习模型<sup>[26]</sup>。为提升 GAN 的修复效果，本文对 GAN 进行结构改进：设计动态位置编码模块，采用动态位置编码替代随机噪声，以增强对缺失位置上下文信息的感知能力；嵌入混合残差空洞卷积网络与通道注意力于生成器中，提高对波动性的特征提取能力；设计混合损失函数，结合缺失率，综合考虑上下文相似性损失、多尺度结构相似性损失与对抗损失。

改进 GAN 网络结构如图 2 所示。

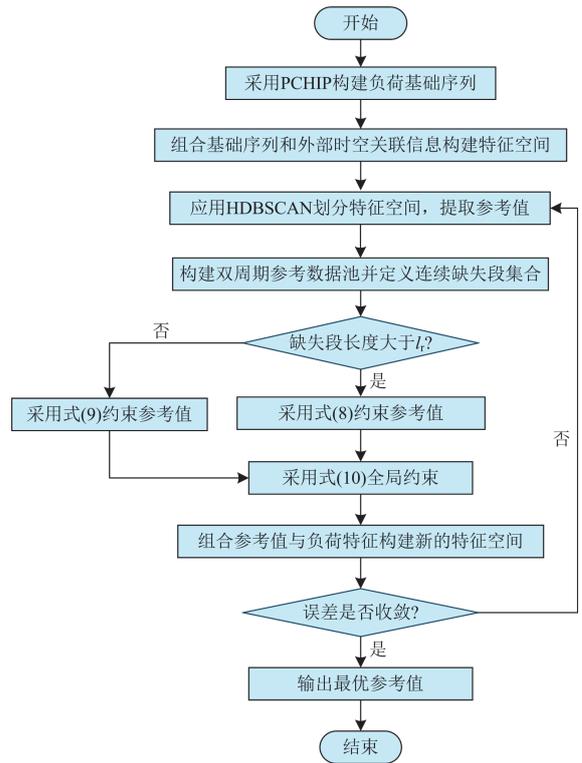


图 1 参考值构建流程

Fig. 1 Flow chart of reference value

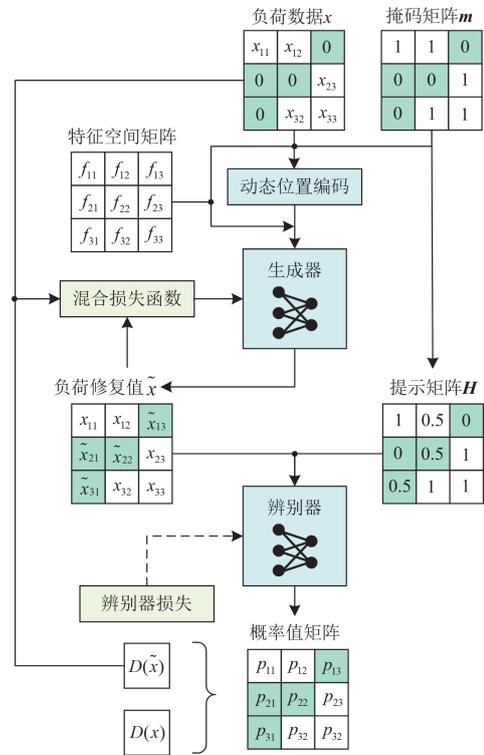


图 2 改进 GAN 网络结构

Fig. 2 Structure of improved GAN network

### 2.1 三阶输入张量构建

张量是一种高维数据形式,是矩阵在更高维度上的推广<sup>[13]</sup>。本文所用数据来源于 Terre Sainte 校区<sup>[27]</sup>(21°20'S, 55°29'E)于 2021 年 1 月 1 日 00:00 至 12 月 31 日 23:50 的电力负荷和外部时空关联信息,采样间隔为 10 min,每日采集 144 个数据,单位为 kW,总计 365 天,样本总数为 52 560 条。考虑到负荷数据的自相关性,将原始负荷数据  $x$ 、掩码矩阵  $m$ 、基础负荷序列  $\bar{x}$ 、参考值  $x_0$ 、外部时空关联信息  $f$  和动态位置编码  $B$  构建一个三阶输入张量  $D$ 。具体方法如下。

1) 将每个采样点  $x$ 、 $m$ 、 $x_0$  和  $B$  构建为一个张量  $e_i = [x, m, x_0, m \odot B]$ , 其中动态位置编码  $B$  获取步骤见 2.2 节。

2) 以日为基本周期,每日长度为 144,将  $e_i$  到  $e_{i+143}$  按顺序堆叠,构建矩阵  $D_i = [e_i, e_{i+1}, \dots, e_{i+143}] \in R^{144 \times 4}$  ( $i = 1, 2, \dots, 364$ )。

3) 将所有  $D_i$  在第三维进行堆叠得到  $D \in R^{364 \times 144 \times 4}$ 。将修复后的张量定义为  $\hat{D}$ 。

### 2.2 动态位置编码模块

采用 GAN 修复缺失负荷数据,生成器以注入随机噪声的缺失负荷序列作为输入,难以有效建模缺失段与上下文数据的动态关联。正弦与余弦函数的位置编码、傅里叶变换编码等方法采用静态表征机制,无法自适应台区负荷的复杂特性,导致缺失区域的上下文信息感知能力显著受限<sup>[28]</sup>。针对上述问题,本文设计了一种动态位置编码模块,具体网络参数设置如附录 A 表 A1 所示。具体流程如下。

1) 将负荷数据  $x$  与掩码矩阵  $m$  按照 2.1 节的方式构建联合输入  $Z \in R^{364 \times 144 \times 2}$ ,采用混合残差空洞卷积<sup>[29]</sup>方式提取局部和全局特征,输出卷积特征  $H'_c$ 。

2) 缺失值的随机分布会稀释卷积的局部响应。将  $H'_c$  和  $Z$  组合输入卷积中,根据上下文自动学习各时间点的贡献权重,并沿时间维对分数做归一化 (Softmax)。

$$A = \theta(W_2 \cdot \text{ReLU}(W_1 \cdot [H'_c, Z])) \quad (11)$$

式中:  $A$  为动态权重矩阵;  $W_1$  为卷积层的权重参数;  $\theta$  为 Softmax 函数。

3) 采用卷积层  $C$  将动态权重分配后的多维特征映射至单通道,得到动态位置编码  $B$ 。 $B$  携带缺失分布的上下文信息,作为生成器的位置编码。

$$B = \text{ReLU}(C(H'_c \odot A)) \quad (12)$$

### 2.3 生成器网络结构

参考值通过特征融合的路径直接嵌入至生成器的输入张量中,为生成器提供逼近真实数据分布的

修复起点。将重构问题转化为对参考值的波形精细化修正。

生成器网络结构主要分为以下 3 个部分,如附录 A 图 A1 所示。

#### 1) 输入编码层

采用 1 维卷积层与 Sigmoid 激活函数,实现对输入张量  $D$  的特征映射。

#### 2) 多尺度特征提取层

由混合残差空洞卷积与通道注意力组成。混合残差空洞卷积由单一维度感受野最大的混合空洞卷积<sup>[30]</sup>(膨胀率序列为[1,2,5],感受野大小如附录 A 图 A2 所示)、批量归一化(batch normalization, BN)以及 ReLU 函数组成,并采用残差连接方式,防止原始信息丢失。结构图如附录 A 图 A3 所示。

#### 3) 重建输出层

采用双层卷积层和 Sigmoid 激活函数输出修复后的张量  $\hat{D}$ 。

生成器详细网络参数设置如附录 A 表 A2 所示。

### 2.4 判别器网络结构

判别器网络结构主要分为以下两个部分。

#### 1) 特征压缩层

由 3 个堆叠的下采样卷积层、批量归一化和线性整流激活函数逐级压缩  $Z$  的特征维度。

#### 2) 分类决策层

采用全局池化融合空间信息、全连接层聚合特征,经 Sigmoid 激活输出真伪概率。

判别器具体网络参数设置如附录 A 表 A3 所示。

### 2.5 混合损失函数

为提升模型的训练效果,本文将多尺度结构相似性损失引入原始损失函数,构建混合损失函数  $L_G$  对生成器进行训练,采用对抗损失函数  $L_D$  对判别器进行训练。

$$L_G = w_r L_r + w_s L_s + L_D \quad (13)$$

$$L_r = \frac{1}{N} \sum_{i=0}^N ((\tilde{x}_i \cdot m_i) - (x_i \cdot m_i))^2 \quad (14)$$

$$L_D = \frac{1}{2} ((-\log(D(x)) - \log(1 - D(\tilde{x}))) \quad (15)$$

$$L_s = \sum_{S \in \{3,7,15\}} \frac{1}{U} \sum |P_S(\tilde{x}), P_S(x)| \quad (16)$$

式中:  $L_r$  为上下文相似性损失;  $L_s$  为多尺度结构相似性损失;  $N$  为  $m$  内有效元素的个数;  $x_i$  和  $\tilde{x}_i$  分别为真实数据和生成数据;  $m_i$  为第  $i$  个掩码值;  $D(x)$  和  $D(\tilde{x})$  分别为判别器对真实数据和生成数据的输出值;  $S$  为下采样尺度,匹配混合空洞卷积网络的感受野;  $U$  为元素总数;  $P_S$  为尺度  $S$  的池化层。

此外,当数据缺失率  $m_r$  越高时,可用于计算多尺度结构相似性损失的真实样本越少,此时应相应增大上下文相似性损失的权重,强化局部数据拟合精度。降低多尺度结构相似性损失的权重,避免模型对有限样本的形态特征过拟合。

$$w_r = \frac{1 + m_r}{1 - m_r} \quad (17)$$

$$w_s = \frac{1 - m_r}{1 + m_r} \quad (18)$$

式中:  $w_r$  和  $w_s$  分别为上下文相似性损失和多尺度结构相似性损失的权重。

### 3 算例分析

测试环境采用了 Python 3.10,并在配置为 AMD Ryzen9 5900HX with Radeon Graphics CPU 和 16.0 GB 内存的系统上进行。

#### 3.1 实验设置

为综合评估本文方法在台区负荷数据方面的性能,在 3.5 节和 3.6 节分别开展 2 项实验: 1) 消融实验,验证参考值和改进 GAN 内各模块对数据修复效果的影响。2) 对比实验,采用本文方法在不同数据缺失场景下与其他数据修复方法进行修复性能比较。

本文所用数据来源于 Terre Sainte 校区于 2021 年 1 月 1 日 00:00 至 12 月 31 日 23:50 的电力负荷和外部时空关联信息。其中外部时空关联信息包含总水平辐照度、相对湿度、光伏出力和天数,为保证模型训练的稳定性与效率,对所有数据进行了归一化处理。随后,将归一化后数据按 4:1 的比例划分为训练集和验证集。采用 Adam 优化器更新模型参数,生成器学习率为  $2 \times 10^{-4}$ ,判别器学习率为  $1 \times 10^{-3}$ 。通过不同长度的  $n$  和  $k$  比较实验(见附录 B 表 B1),当  $n$  和  $k$  取 4 时约束效果最好。为匹配局部窗口约束效果(见式(8)),不超过窗口最大值,将缺失阈值长度设置值为 9。HDBSCAN 算法的超参数通过网格搜索确定,以簇内负荷平均方差最小为指向,具体超参数设置见附录 B 表 B2。

通过图 3 可以看出台区负荷曲线呈现出典型的周期性特征,工作日峰值显著高于周末,以及在同类日期之间出现大幅波动,反映出负荷时序的随机性、复杂性以及周期性。

针对台区负荷数据缺失场景的实证研究需充分考虑实际工况特征。通常情况下,低压台区功率数据缺失率通常维持在 40% 以内<sup>[1]</sup>,且不同缺失模式具有显著差异性,与因通信攻击或信道干扰引发的用户侧电力数据随机性缺失不同,连续多日数据

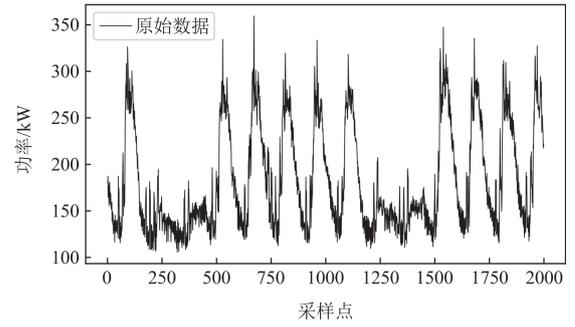


图 3 测试集部分负荷曲线

Fig. 3 Partial load curves of test set

缺失多由计量装置故障、通信设备物理性损毁等硬件问题导致,通常表现持续性数据丢失。基于此特征分布规律,本文从两方面对所提的数据修复模型进行验证。1) 针对随机缺失场景,设置 10%~50% 渐进式缺失率进行仿真验证。2) 针对设备故障引发的连续性缺失场景,本文设定连续 1—4 日台区级负荷数据缺失作为极端工况测试条件。

#### 3.2 评价函数

本实验采用数据修复效果测试常用的 3 个评价指标,分别为平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)以及平均绝对百分比误差(mean absolute percentage error, MAPE)。3 个评价指标越小,代表模型重构的效果越好。评价指标如式(19)~式(21)所示。

$$E_{MAE} = \frac{1}{K} \sum_{i=1}^K |y_i - y_i^*| \quad (19)$$

$$E_{RMSE} = \sqrt{\frac{1}{K} \sum_{i=1}^K (y_i - y_i^*)^2} \quad (20)$$

$$E_{MAPE} = \frac{1}{K} \sum_{i=1}^K \left| \frac{y_i - y_i^*}{y_i} \right| \times 100\% \quad (21)$$

式中:  $y_i$  为  $t$  时刻负荷的真实值;  $y_i^*$  为  $t$  时刻修复后数值;  $K$  为样本数量。

#### 3.3 动态权重分布分析

参数初始化策略对动态位置编码模块中动态权重初始分布影响重大。为验证动态位置编码模块所生成动态权重的合理性,在 50% 随机缺失场景下,对 5 种不同初始化策略下训练后的动态权重分布情况进行分析,初始化策略分别为默认初始化、Xavier 初始化<sup>[31]</sup>、Kaiming 初始化<sup>[32]</sup>、随机初始化和零值初始化。如图 4 所示, Xavier 初始化在高权重区域的表现也相对较好,但低权重区域的集中度较高。默认和随机初始化则表现出较为保守的分布模式,而零值初始化完全无法产生有效的注意力分布。Kaiming 初始化在产生多样化注意力分布方面表现

最佳, 能够在保持大部分注意力集中在低权重区域的同时, 分配更多注意力到中等和高权重区域。这种分布模式最有利于模型区分重要和次要信息, 提高注意力机制的有效性。同时, 在附录 B 表 B3 和表 B4 中分别给出权重分布统计特征和不同初始化策略的数据修复效果。根据分析结果, 动态位置编码模块采用 Kaiming 初始化策略。

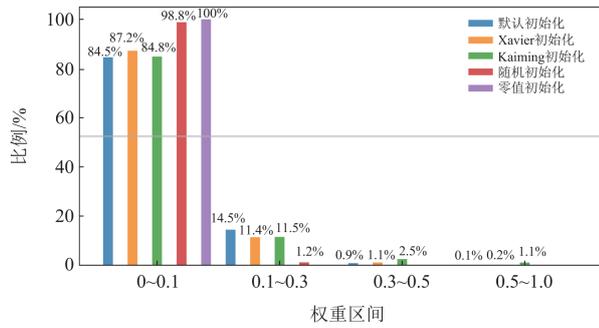


图 4 不同初始化策略动态注意力权重分布

Fig. 4 Dynamic attention weight distribution under different initialization strategies

### 3.4 参考值迭代约束实验

为获取最优参考值并验证动态时序边界约束机制的有效性, 在 50% 随机缺失的场景下, 计算每轮聚类约束前后的参考值与真实负荷值之间的 MAPE。从图 5 可以看出, 约束后的参考值误差在每轮聚类中明显优于未约束的参考值, 其误差随着迭代次数增加不断下降, 于第 6 轮迭代后误差趋于稳定。本文采用至少 6 轮迭代后生成的参考值。

### 3.5 消融实验

消融实验组 1: 评估混合残差空洞卷积、参考

表 1 消融实验组 1 的修复效果性能指标

Table 1 Restoration performance evaluation index for ablation experiment group 1

缺失场景	MAE/kW				RMSE/kW				MAPE/%				
	实验 1	实验 2	实验 3	实验 4	实验 1	实验 2	实验 3	实验 4	实验 1	实验 2	实验 3	实验 4	
随机缺失	10%	1.0950	1.1418	0.8349	0.6744	4.4101	4.7530	3.7229	3.0297	0.6773	0.6668	0.4730	0.3870
	20%	2.1054	2.0665	1.1870	1.2077	5.8712	5.8677	3.8333	3.9338	1.2831	1.2414	0.6556	0.6571
	30%	3.3479	3.3482	2.9247	2.5391	8.1190	8.1098	7.4006	6.4067	2.0020	1.9759	1.6118	1.4336
	40%	4.8145	4.7664	3.9315	3.4270	9.8045	9.8226	8.3123	7.2605	2.8470	2.7921	2.1854	1.9660
	50%	6.4234	6.0466	4.9697	4.6560	11.6948	11.1479	9.9301	9.2587	3.8267	3.6539	2.7407	2.5889
连续缺失	1 天	1.2035	1.1700	0.7512	0.7263	6.1231	6.0036	3.5286	3.4158	0.7983	0.7712	0.5220	0.5017
	2 天	2.9640	2.7844	2.4982	2.4398	10.8527	10.4502	9.0939	8.8965	1.4735	1.4295	1.2233	1.1829
	3 天	3.8622	3.7538	3.5943	3.5851	11.1173	11.0213	10.6010	10.5502	2.2991	2.2054	1.8206	1.8176
	4 天	5.8953	6.6806	4.4669	4.3349	14.9787	17.8289	10.6004	10.2014	3.3605	3.4965	2.7742	2.7211

由表 1 结果可知, 对比消融实验组中各方案的误差指标, 可归纳出以下结论。

1) 在随机缺失与连续缺失两种场景下, 采用混合膨胀率[1,2,5]的实验 2 相较于采用固定膨胀率[2,2,2]

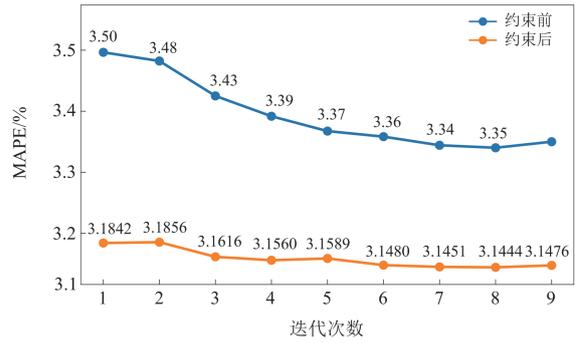


图 5 参考值迭代约束效果

Fig. 5 Effects of reference-value iteration constraints

值以及混合损失函数的有效性, 参见表 1。

在不同缺失率的随机缺失和不同长度的连续缺失数据集下, 设计了以下 4 组消融实验。

实验 1: 构建基于固定膨胀率[2,2,2]残差空洞卷积的 GAN 作为基准模型。其输入张量维度为  $144 \times 6$ , 由负荷数据、外部时空关联特征和缺失掩码矩阵沿特征维度拼接构成, 损失函数直接引用文献[19]的设计。

实验 2: 构建基于混合残差空洞卷积的 GAN 作为基准模型。以验证混合膨胀率[1,2,5]对模型修复精度的影响。

实验 3: 在实验 2 的基础之上, 引入参考值, 输入张量改为 2.1 节所构建的输入, 用以验证参考值对数据修复效果的作用。

实验 4: 在实验 3 的基础上, 修改损失函数为 2.5 节中的混合损失函数, 以评估混合损失函数在加速误差收敛及提升模型泛化能力方面的有效性。

的实验 1 在多项指标上均表现出更优的性能。在 50% 高随机缺失率下, MAE 降幅达 5.9%, MAPE 改善幅度为 4.5%。这表明混合膨胀率通过融合不同尺度的感受野, 既增强了对局部突变特征的捕捉, 也提升了对

长程时序关联的建模能力,从而在不同缺失模式下均体现出更好的特征提取与修复稳定性。

2) 在引入参考值后,模型修复精度全面提高,在40%随机缺失下,MAPE从实验2的2.7921%大幅降至2.1854%,精度提升达21.8%。在连续缺失4天的极端场景中,RMSE降幅超过40%。实验结果证实,通过融合外部时空特征与聚类优化得到的参考值,为生成器提供了关键的结构性引导,使修复值更贴近真实负荷变化模式。

3) 损失函数融合了多尺度结构相似性度量,使模型在像素级误差和结构一致性方面同时进行优化。在有参考值的基础上,增加混合损失项仍能带来可观的精度提升,50%随机缺失下MAPE进一步降低5.5%,连续缺失4天场景中RMSE额外下降3.8%。

消融实验组2:验证噪声输入以及动态位置编

表2 消融实验组2的修复效果性能指标

Table 2 Restoration performance evaluation index for ablation experiment group 2

缺失场景	MAE/kW				RMSE/kW				MAPE/%				
	实验5	实验6	实验7	实验8	实验5	实验6	实验7	实验8	实验5	实验6	实验7	实验8	
随机 缺失	10%	0.6744	0.6785	0.4368	0.3658	3.0297	2.9458	1.8840	1.4876	0.3870	0.3909	0.2586	0.2394
	20%	1.2077	1.0714	0.9841	0.9462	3.9338	3.1289	2.8981	2.7894	0.6571	0.6337	0.5876	0.5668
	30%	2.5391	2.6892	2.4978	2.4327	6.4067	6.7254	6.2768	6.2049	1.4336	1.4525	1.4004	1.3845
	40%	3.4270	3.3659	3.2286	3.1844	7.2605	7.3288	6.8607	6.6970	1.9660	1.8977	1.7961	1.8284
	50%	4.6560	4.5810	4.5164	4.4495	9.2587	8.9473	8.9745	8.6261	2.5889	2.5460	2.5255	2.5102
连续 缺失	1天	0.7263	0.6233	0.7230	0.6078	3.4158	2.9408	3.5426	2.8957	0.5017	0.4561	0.4888	0.4438
	2天	2.4398	2.2166	2.0582	2.0203	8.8965	7.3446	6.8778	7.2867	1.1829	1.1404	1.1112	1.0451
	3天	3.5851	3.7523	3.7403	3.5423	10.5502	9.9566	9.9353	9.7353	1.8176	1.7987	1.7980	1.7787
	4天	4.3349	4.3615	4.1806	4.2757	10.2014	10.3976	10.0410	10.3657	2.7211	2.7096	2.6718	2.6543

从表2可以得出以下结论。

1) 噪声输入对模型修复效果的影响与缺失模式密切相关。在随机缺失场景中,引入噪声实验组相较于无噪声实验组并未带来显著性能增益。然而,在连续缺失场景中,噪声体现出一定的正向作用,如连续缺失2天时,实验6的MAPE较实验5降低约3.6%,说明噪声在一定程度上可增强模型对长时缺失中不确定性模式的泛化能力。

2) 动态位置编码模块的引入显著提升了模型的修复性能,体现出其有效捕捉缺失上下文信息的能力。实验7在实验6基础上引入该模块后,在所有缺失场景下均能进一步提升精度,如随机缺失10%时MAPE降低33.8%,表明动态位置编码模块能够有效补偿噪声引入的不确定性,增强缺失区域的感知和重建能力。

3) 实验8在所有缺失场景下均达到最佳性能,表明用动态位置编码替代随机噪声为最优组合,凸显出动态位置编码在增强模型对负荷时序结构感知方面的关键作用。

码对GAN模型缺失值修复性能的作用,参见表2。

在不同缺失率的随机缺失和不同长度的连续缺失数据集上开展以下4个实验。

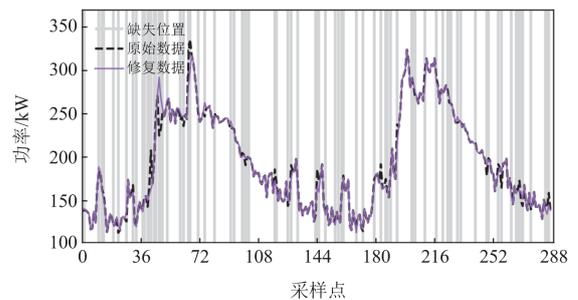
实验5:在不引入噪声输入的前提下,将原始数据直接输入GAN,以考察无噪声条件对修复精度的影响。

实验6:在GAN的负荷数据中引入噪声输入,通过对比修复结果评估噪声对模型台区负荷修复性能的正负影响。

实验7:基于实验6设置,引入动态位置编码模块,以验证二者协同作用下对数据修复的优化效果。

实验8:在实验5方案基础上,在负荷数据中引入动态位置编码,检验动态位置编码替代噪声输入后对修复精度的提升作用。

如图6所示,4组实验均能有效修复整体趋势。在负荷突变点等细节处,实验7与实验8的修复效果显著优于实验5与实验6,证实了动态位置编码对提升细节修复能力的作用。在实验8的修复图中,可以看出修复曲线(蓝色)与参考值曲线(红色)在整体趋势上高度一致,但在细节处生成器对其进行了进一步修正,使其更贴近真实数据(黑色)。进一步证实了参考值提供了接近数据真实分布的修复起点。



(a) 实验5

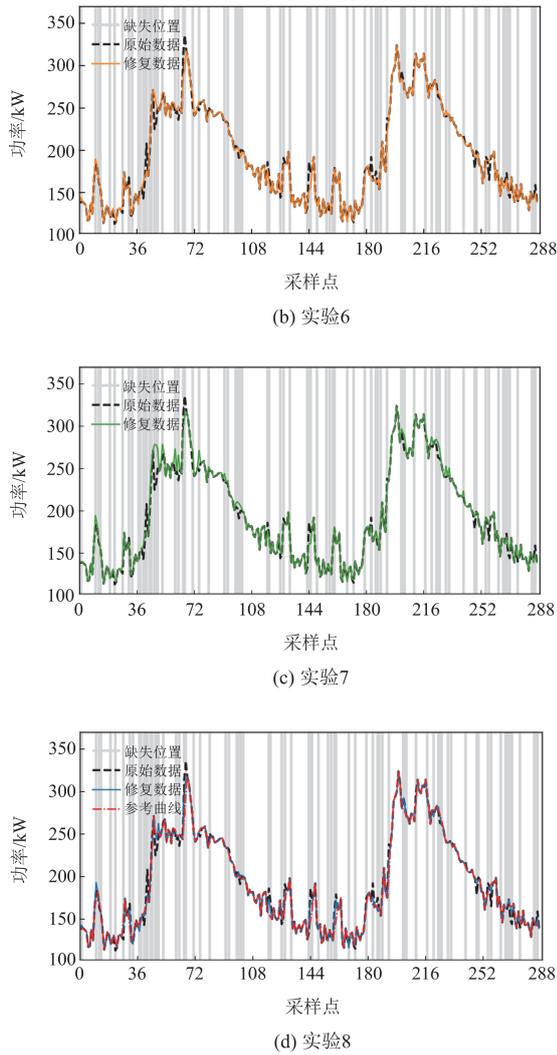


图 6 30%随机缺失场景修复结果

Fig. 6 Restoration effect at 30% random missing scenario

### 3.6 数据修复方法对比

为进一步验证本文方法的有效性,使用三次样条插值、自编码以及残差U型网络的方法进行实验对比。对比实验在随机缺失和连续缺失的场景下进行,各模型误差对比结果如图7所示。可以看出,在不同缺失率和缺失时长的条件下,本文方法始终表现出最优且最稳定的性能。随着缺失率的增加或缺失时长的延长,所有方法的误差均呈现上升趋势,然而本文模型的增长幅度显著低于其他对比方法,其误差曲线更为平缓,显示出优异的鲁棒性。与三次样条插值相比,本文方法能够更有效地捕捉负荷数据中的复杂时序依赖关系和波动模式,避免了传统方法在高缺失情况下的性能急剧恶化。与其他神经网络方法相比,本文利用参考值构建方法、动态位置编码和多尺度特征提取机制,在修复精度和稳定性

方面也体现出明显优势,验证了本文方法在台区负荷数据修复任务中的有效性和先进性。

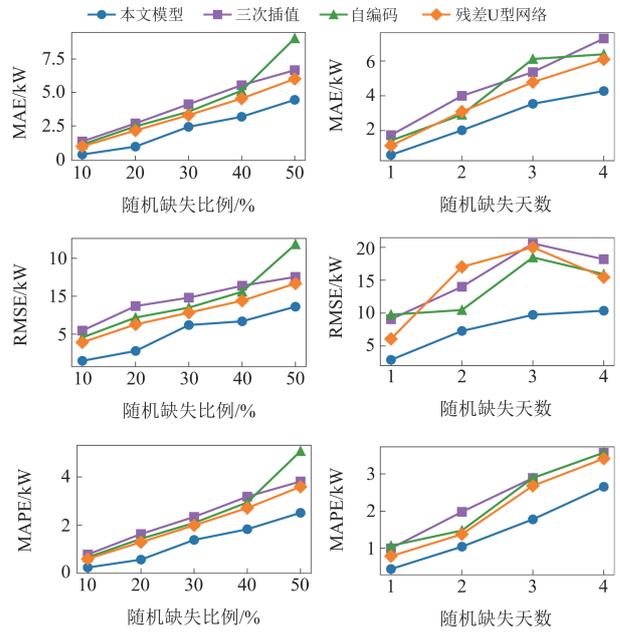


图 7 缺失情况下模型误差对比结果

Fig. 7 Comparison results of model error under missing condition

图8展示了本文模型对连续一天缺失数据的修复效果。修复曲线与原始曲线在整体趋势上高度一致,较为准确地还原了缺失区间内负荷自高点向低谷下降的拐点位置。在细节波动方面,尽管模型对部分缺失区域平滑处理,但仍能捕捉到关键时段的短时小幅波动,形态与原始数据大致吻合。

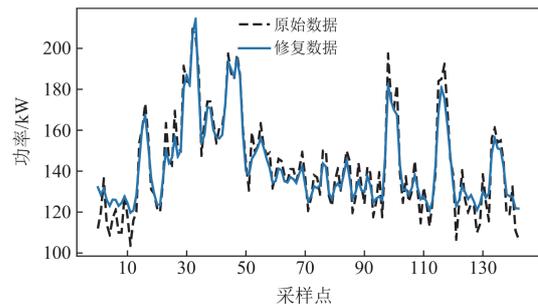


图 8 连续 1 天缺失修复结果

Fig. 8 Restoration results for one consecutive missing day

## 4 结论

本文提出了一种融合参考值与改进生成对抗网络的台区负荷数据修复方法,并在多个不同程度随机和连续缺失场景下验证了所提方法的可行性与优越性,所得结论如下。

1) 参考值的引进,提供了一个贴合真实数据分布的修复起点,约束了生成器的可行解空间。相较

于无参考值方案，随机缺失场景修复精度提高了20%，连续缺失场景修复精度提高了约40%。

2) 对比无噪声与含噪声方案，发现在台区负荷长时间连续缺失中，含噪声方案有着更加优异的修复效果。

3) 提出的动态位置编码模块替代传统 GAN 中的随机噪声输入，能够自适应捕捉缺失位置的上下文信息与时空依赖关系，增强了模型对复杂缺失模式的感知能力。相比含噪声输入方案，该模块在各项评价指标上均带来显著提升，验证了其在提升修复精度与稳定性方面的有效性。

4) 融合上下文相似性损失、多尺度结构相似性损失与对抗损失的混合损失函数，能够协同优化局部细节与整体结构的一致性。在不同缺失率下自适应调整损失权重，进一步提高了模型的泛化能力和修复效果。

本文后续可将研究范围扩展至光伏、风力等多种场景，以进一步验证方法的通用性。此外，当前工作未考虑不同台区之间负荷关联特性，后续可引入跨台区关联特征，并借助更大规模数据集进行深入分析，以提升模型的泛化能力和实用性。

附录 A

表 A1 动态位置编码模块详细网络参数设置

Table A1 Detailed network parameter settings of dynamic position coding module

模块名称	子模块	参数配置	输入维度	输出维度	激活函数	归一化方式
混合残差空洞卷积	第一层空洞卷积	卷积核为 3，膨胀率为 1，填充为 2	[58,2,144]	[58,8,144]	ReLU	BN
	第二层空洞卷积	卷积核为 3，膨胀率为 2，填充为 2	[58,8,144]	[58,16,144]	ReLU	BN
	第三层空洞卷积	卷积核为 3，膨胀率为 5，填充为 2	[58,16,144]	[58,16,144]	ReLU	BN
动态权重分配	第一层卷积	卷积核为 1，填充为 0，步长为 1	[58,18,144]	[58,4,144]	ReLU	—
	第二层卷积	卷积核为 1，填充为 0，步长为 1	[58,4,144]	[58,1,144]	—	—
输出层	卷积层 C	卷积核为 3，填充为 1，步长为 1	[58,16,144]	[58,1,144]	—	—

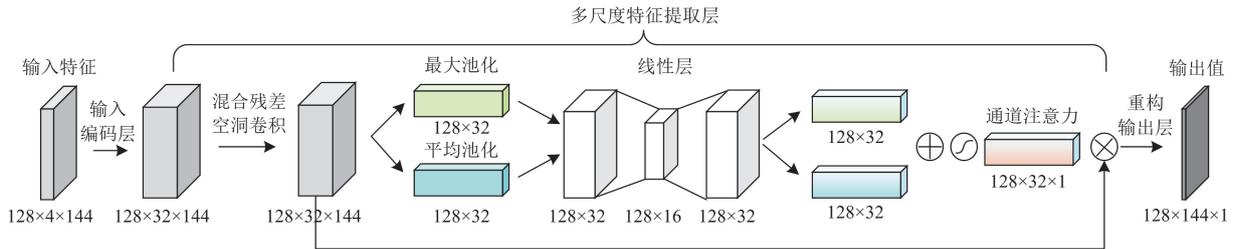


图 A1 生成器结构

Fig. A1 Structure of generator

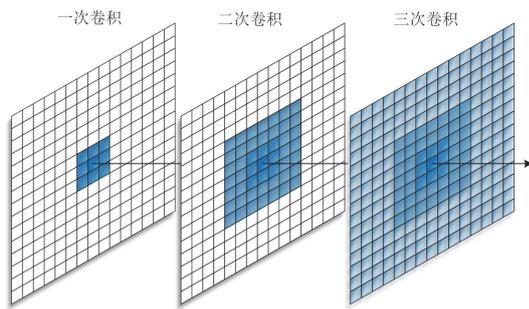


图 A2 混合空洞卷积三次卷积感受野

Fig. A2 Hybrid dilated convolution with triple-scale receptive fields

从图 A2 可以看出，本文采用膨胀率序列 [1,2,5]，确保卷积感知域覆盖连续，无信息缺失，避免了像固定膨胀率 [2,2,2] 出现的网格效应<sup>[29]</sup>。同

时，采用指数增长的膨胀率以快速扩大感受野，使网络单元能捕获台区负荷中长效依赖关系。

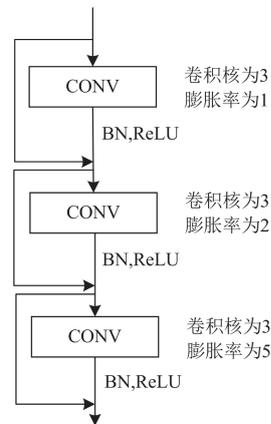


图 A3 混合残差空洞卷积结构

Fig. A3 Structure of residual hybrid dilated convolution

表 A2 生成器详细网络参数设置

Table A2 Detailed network parameter settings of the generator

模块名称	子模块	参数配置	输入维度	输出维度	激活函数	归一化方式
输入层	1 维卷积	卷积核为 3, 填充为 1, 步长为 1	[58,5,144]	[58,32,144]	Sigmoid	BN
特征提取层	第一层空洞卷积	卷积核为 3, 膨胀率为 1, 填充为 2	[58,32,144]	[58,32,144]	ReLU	BN
	第二层空洞卷积	卷积核为 3, 膨胀率为 1, 填充为 2	[58,32,144]	[58,32,144]	ReLU	BN
	第三层空洞卷积	卷积核为 3, 膨胀率为 1, 填充为 2	[58,32,144]	[58,32,144]	ReLU	BN
	通道注意力	线性层 1 输入维度为 32, 输出维度为 16 线性层 2 输入维度为 16, 输出维度为 32	[58,32]	[58,32]	Sigmoid	—
输出层	第一层卷积	卷积核=3, 填充=1, 步长=1	[58,32,144]	[58,16,144]	ReLU	—
	第二层卷积	卷积核=1, 填充=0, 步长=1	[58,16,144]	[58,1,144]	Sigmoid	—

表 A3 判别器详细网络参数设置

Table A3 Detailed network parameter settings of the discriminator

模块名称	子模块	参数配置	输入维度	输出维度	激活函数	归一化方式
特征压缩层	第一层 1 维卷积层	卷积核为 5, 填充为 2, 步长为 1	[58,2,144]	[58,16,144]	ReLU	—
	第二层 1 维卷积层	卷积核为 5, 填充为 2, 步长为 2	[58,16,144]	[58,32,72]	ReLU	BN
	第三层 1 维卷积层	卷积核为 5, 填充为 2, 步长为 2	[58,32,72]	[58,64,36]	ReLU	BN
分类决策层	池化层	—	[58,64,36]	[58,64,1]	—	—
	全连接层	输入维为 64, 输出维度 1	[58,64]	[58,1]	Sigmoid	—

附录 B

表 B1 50%随机缺失下不同长度  $n$  和  $k$  的约束效果性能指标

Table B1 Completion performance evaluation index of constraint effectiveness at different sequence lengths at 50% missing rate

$n$ 和 $k$ 大小	MAE/kW	RMSE/kW	MAPE/%
1	5.9602	11.3471	3.4610
2	5.6796	10.8325	3.2856
3	5.5603	10.6128	3.2106
4	5.5272	10.5487	3.1842
5	5.5416	10.5769	3.1932
6	5.5532	10.6017	3.1977
7	5.5530	10.6326	3.1938
8	5.5677	10.6744	3.2007
9	5.5854	10.7042	3.2115
10	5.6091	10.7341	3.2248

从表 B1 可以看出当  $n$  和  $k$  设置为 4 时约束效果最好。一旦取值偏离 4, 所有评价指标均呈现显著增加趋势, 表明约束效果随之下降。

簇内同质性越高, 获得参考值的代表性越高, 表 B2 中的超参数通过网格搜索确定, 搜索目标为簇内负荷平均方差最小。采用表 B2 中搜索出的最优参数组合进行聚类, 得到轮廓系数为 0.6009。归一化数据的簇内负荷平均方差为 0.0094; 噪声比例为 2.85%。该结果表明在所选超参数下聚类结构清晰且簇内同质性较好。

图 B1 为超参数敏感性分析结果。由图可见, 当最小簇大小(min\_cluster\_size)取 90 且核心点邻居

数(min\_samples)取 15 时, 簇内负荷方差值达到最优; 密度阈值(density threshold)取值过大或过小均会削弱聚类性能; 在距离度量上, 曼哈顿距离(Manhattan)和欧氏距离(Euclidean)优于切比雪夫距离(Chebyshev); 而所谓的稳定性平滑系数对聚类效果的影响较小, 表现出较强的鲁棒性。

表 B2 HDBSCAN 超参数

Table B2 Parameter settings of HDBSCAN

超参数名称	参数设定值	参数搜索范围
最小簇大小(min_cluster_size)	90	[40,90]
核心点邻居数(min_samples)	15	[10,35]
距离度量(metric)	Euclidean	['Euclidean', 'Manhattan', 'Chebyshev']
簇树切分策略(cluster_selection_method)	'com'	['com', 'leaf']
稳定性平滑系数(alpha)	1	[0.5,1.5]
最小密度跳跃阈值(cluster_selection_epsilon)	0.3	[0.25,0.35]

如表 B3 所示, 不同初始化策略对注意力权重的初始分布具有显著影响。Kaiming 正态初始化产生了高度不均匀的分布, 其权重值分布在极宽范围内。这表明模型在初始状态下即能区分不同时间点的重要性, 将注意力聚焦于关键上下文位置, 为后续训练提供了理想的起点。相比之下, Xavier 初始化、默认初始化和常数初始化产生的权重分布均匀, 缺乏对关键时间点的区分能力。特别是零初始化, 其权重分布完全无法反映不同时间点的重要性差异。

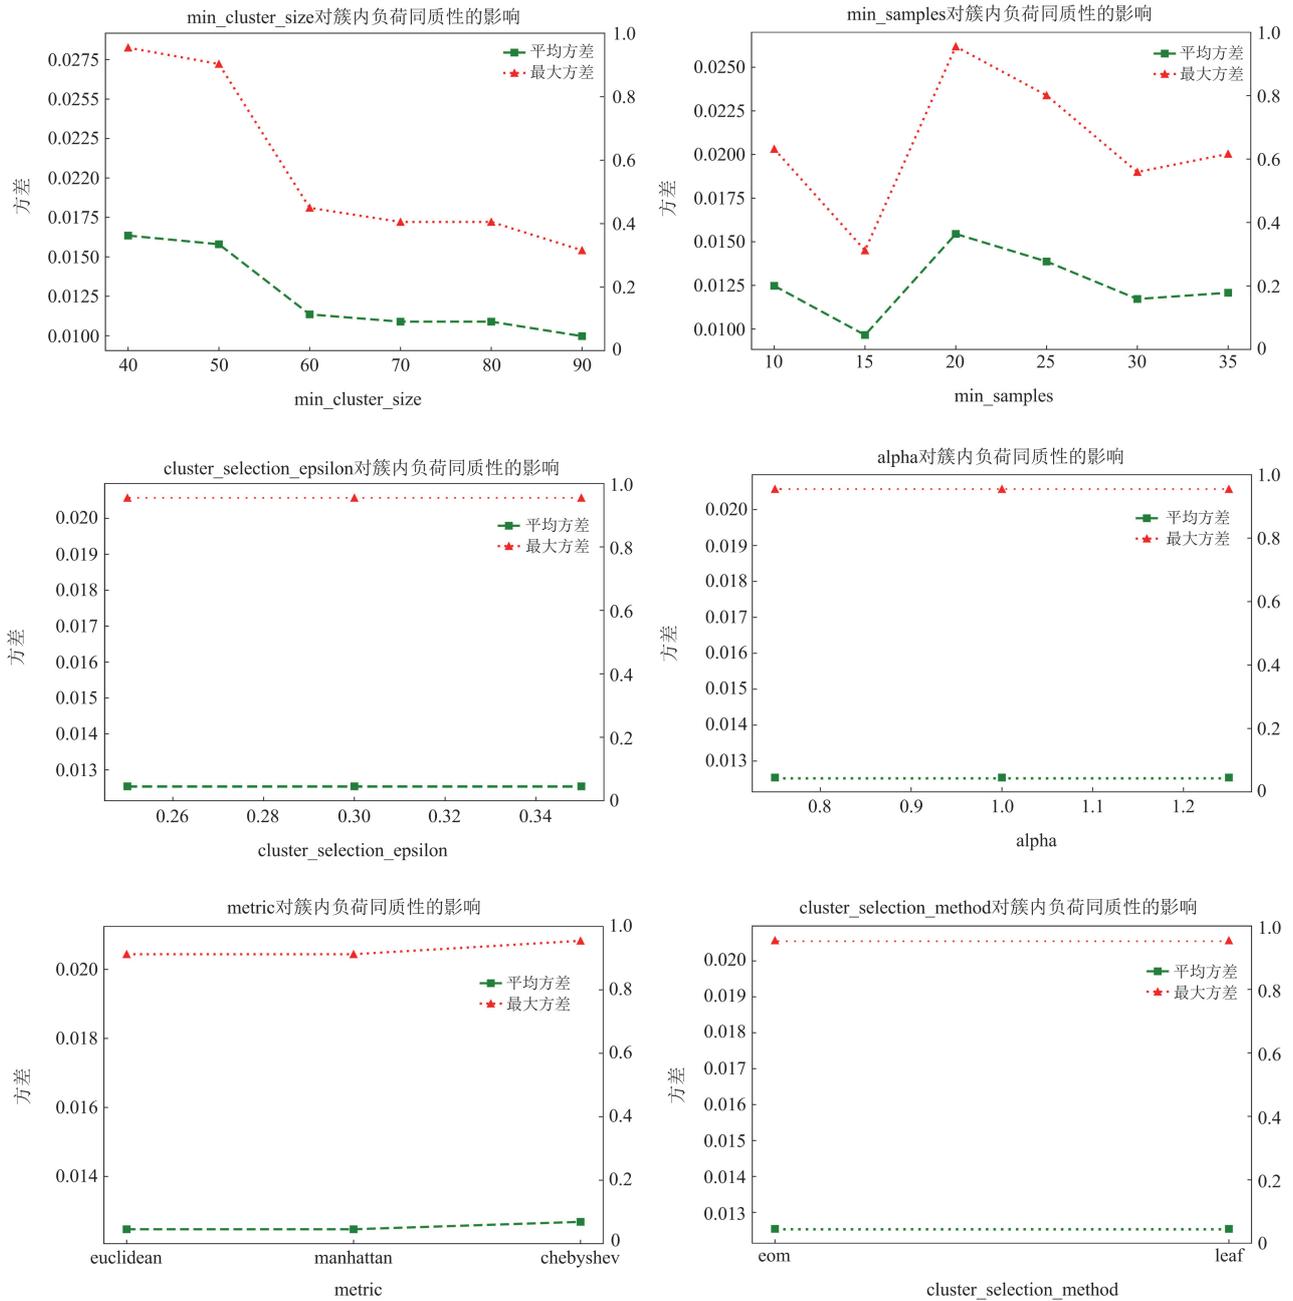


图 B1 HDBSCAN 超参数对簇内负荷方差的影响

Fig. B1 Effect of HDBSCAN hyperparameters on within-cluster load variance

表 B3 50%随机缺失下不同初始化策略下权重分布情况

Table B3 Weight distribution under different initialization strategies at 50% random missing rate

	原始初始化	Xavie 初始化	Kaiming 初始化	随机初始化	零初始化
标准差	0.0686	0.0694	0.1043	0.0373	0.0000
最小值	0.0000	0.0000	0.0000	0.0074	0.0417
最大值	0.7240	0.8631	0.9936	0.1577	0.0417
中位数	0.0093	0.0150	0.0001	0.0360	0.0417
偏度	2.7503	3.4418	3.7441	0.8387	0.0000
峰度	10.8144	17.4217	17.9121	0.2282	0.0000

表 B4 不同缺失场景下不同初始化策略修复效果性能指标

Table B4 Restoration performance evaluation index of different initialization strategies at different missing rate

性能指标	缺失场景	默认初始化	Xavie 初始化	Kaiming 初始化	随机初始化	零初始化
$E_{MAPE}$	10%随机缺失	0.2494	0.2404	0.2394	0.2414	1.8632
	50%随机缺失	2.7204	2.7509	2.5102	2.5829	10.2539
	连续两天缺失	1.2300	1.3239	1.0451	1.0665	3.2168

根据表 B4 得出不同初始化策略的修复结果来看, 针对 ReLU 激活函数设计的 Kaiming<sup>[31]</sup>初始化策略能够为动态位置编码模块提供最佳的初始状态。

从图 B2 可以看出未归一化会导致权重分布相对均匀, 未能充分学习区分度, 导致模型难以区别关键位置。同时, 在 50%随机缺失场景下, 其 MAPE 为 2.7487%, 修复精度低于归一化后的模型。表 B5 通过对不同膨胀率组合的对比实验发现, 混合膨胀率设计[1,2,5]在随机缺失与连续缺失场景下均表现出最优的综合性能。该序列有效避免了[2,4,6]和[3,6,9]等组合的网格效应, 确保了感受野连续无空洞。同时, 相较于[1,3,5]等方案, [1,2,5]在细节捕捉与长程依赖间取得更好平衡: 其小膨胀率保障了对负荷短期波动与突变点的精细捕捉, 而渐进式中大膨胀率显著增强了对长程周期的建模能力。实验表

明, [1,2,5]在多项指标上显著优于其他混合组合, 尤其在高缺失率和长连续缺失场景中稳定性更强, 证明了其优异的综合修复性能与泛化能力。

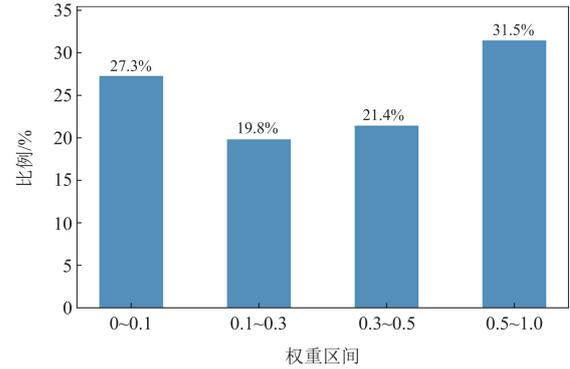


图 B2 未归一化下的动态权重分布

Fig. B2 Dynamic weight distribution without normalization

表 B5 不同膨胀率组合下空洞卷积网络的修复效果性能指标

Table B5 Restoration performance evaluation index of dilated convolutional networks' reconstruction under different combinations of dilation rates

缺失场景	MAE/kW				RMSE/kW				MAPE/%				
	[2,4,6]	[3,6,9]	[2,2,5]	[1,3,5]	[2,4,6]	[3,6,9]	[2,2,5]	[1,3,5]	[2,4,6]	[3,6,9]	[2,2,5]	[1,3,5]	
随机缺失	10%	1.1447	1.1146	1.1354	1.1020	4.6280	4.4260	4.6421	4.4237	0.6992	0.6932	0.6920	0.6773
	20%	2.2728	2.1838	2.2593	2.2243	6.2961	6.0580	6.4220	6.2074	1.4014	1.3152	1.3442	1.3487
	30%	3.4812	3.4400	3.5566	3.4581	8.3952	8.2603	8.4884	8.2992	2.0626	2.0584	2.1184	2.0733
	40%	4.8628	4.7572	4.7289	4.9301	9.8853	9.7709	9.6868	10.0659	2.8532	2.8185	2.7909	2.8852
	50%	6.1919	6.5911	6.4927	6.3206	11.3147	11.9103	11.7425	11.5493	3.7380	3.9519	3.8828	3.7868
连续缺失	1天	1.2456	1.4584	1.2455	1.2696	6.1626	7.2111	6.2280	6.3399	0.8310	0.9384	0.8367	0.8426
	2天	2.9037	2.9127	2.9525	2.9525	10.7859	10.5667	10.9085	10.9085	1.4441	1.4683	1.4706	1.4706
	3天	3.9388	3.8697	3.9998	3.8307	11.3291	11.362	11.5335	11.2856	2.3500	2.2764	2.3648	2.2595
	4天	6.0790	6.2964	6.6008	6.2356	15.1914	15.5412	16.8387	15.4531	3.5259	3.6561	3.6604	3.6595

表 B6 中实验 9 设置的损失函数权重策略如式 (B1)所示。

$$L_G = L_r + L_s + L_D \quad (B1)$$

实验 10 设置的损失函数权重策略如式(B2)所示。

$$L_G = w_r L_r + w_s L_s + L_D \quad (B2)$$

实验 11 设置的损失函数权重策略<sup>[18]</sup>如式(B3)一式(B5)所示。

$$w_r = \frac{m_r}{1 + m_r} \quad (B3)$$

$$w_s = \frac{1}{1 + m_r} \quad (B4)$$

$$L_G = w_r L_r + w_s L_s + L_D \quad (B5)$$

为验证本文所提损失权重自适应策略的合理性, 将其与固定权重、反向权重及文献[18]策略进行对比。结果表明, 本文策略在多场景下均表现出最优或次优的稳定性与精度, 尤其在 20%与 30%随机缺失率下, 其 MAPE 显著低于对比方案, 证实了动态调整权重的必要性。反向权重策略的失效从反面强有力地论证了本文设计的正确性, 其在高缺失率下削弱上下文约束、强调全局结构的做法与修复任务本质相悖, 导致多项指标持续劣化。

表 B6 不同损失权重策略下模型的修复效果性能指标

Table B6 Completion performance evaluation index of different loss-weighting strategies

缺失场景	MAE/kW			RMSE/kW			MAPE/%			
	实验 9	实验 10	实验 11	实验 9	实验 10	实验 11	实验 9	实验 10	实验 11	
随机 缺失	10%	0.6699	0.7003	0.7083	2.9074	3.0882	3.0761	0.3976	0.4111	0.4180
	20%	1.4781	1.4767	1.4590	4.7747	4.7012	4.6304	0.8086	0.8314	0.8240
	30%	2.6900	2.5151	2.4484	6.4394	5.9190	5.9794	1.5543	1.4729	1.4170
	40%	3.8342	3.7478	3.4744	7.7803	7.6801	7.1740	2.2558	2.2020	2.0512
	50%	4.7925	4.6977	4.6409	8.1151	8.8340	8.9306	2.6814	2.7980	2.6212
连续 缺失	1 天	1.0064	0.7108	0.6909	4.7120	3.3564	3.2914	0.7044	0.5268	0.5087
	2 天	2.4067	2.4039	2.2555	8.0460	8.2831	7.5347	1.2512	1.2182	1.1866
	3 天	3.6511	3.8879	3.5979	9.9983	10.7175	10.0825	1.8443	1.9026	1.8209
	4 天	4.1403	4.8280	4.6409	10.4037	12.1190	10.2663	2.7364	2.8388	2.7230

参考文献

[1] 郭耀扬, 张利, 郝颖, 等. 基于分行业用电特性与多因素影响的区域级短期用电负荷曲线预测[J]. 电力系统保护与控制, 2025, 53(13): 82-92.  
GUO Yaoyang, ZHANG Li, HAO Ying, et al. Regional short-term electricity load curve forecasting based on industry electricity consumption characteristics and multi-factor effects[J]. Power System Protection and Control, 2025, 53(13): 82-92.

[2] 余凯峰, 吐松江·卡日, 张紫薇, 等. 基于级联 MCNN-MMLP 双残差网络的短期负荷预测[J]. 电力系统保护与控制, 2025, 53(2): 151-162.  
YU Kaifeng, TUSONGJIANG·Kari, ZHANG Ziwei, et al. Short-term load forecasting based on a cascade MCNN-MMLP double residual network[J]. Power System Protection and Control, 2025, 53(2): 151-162.

[3] ZHU S, MA H, CHEN L, et al. Short-term load forecasting of an integrated energy system based on STL-CPLE with multitask learning[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 71-92.

[4] 黎子律, 王星华, 伏辰阳, 等. 考虑可分解多尺度时序特征融合的规划态光荷联合场景生成[J]. 电力系统保护与控制, 2025, 53(12): 152-164.  
LI Zilü, WANG Xinghua, FU Chenyang, et al. Planning-state PV-load joint scenario generation considering decomposable multi-scale temporal feature fusion[J]. Power System Protection and Control, 2025, 53(12): 152-164.

[5] 李虹, 韩雨萌. 基于 LSTM-CGAN 的多微网数据驱动分布鲁棒协同优化运行策略[J]. 电力系统保护与控制, 2024, 52(18): 133-148.  
LI Hong, HAN Yumeng. Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN[J]. Power System Protection and Control, 2024, 52(18): 133-148.

[6] WANG J, DU W, YANG Y, et al. Deep learning for multivariate time series imputation: a survey[J]. arXiv preprint, 2024, 16: 5079-5112.

[7] LIU Y, WANG C, ZHANG L. Decision tree based predictive models for breast cancer survivability on imbalanced data[C] // 2009 3rd International Conference on Bioinformatics and Biomedical Engineering, June 11-13, 2009, Beijing, China: 1-4.

[8] 朱倩雯, 叶林, 赵永宁, 等. 风电场输出功率异常数据识别与重构方法研究[J]. 电力系统保护与控制, 2015, 43(3): 38-45.  
ZHU Qianwen, YE Lin, ZHAO Yongning, et al. Methods for elimination and reconstruction of abnormal power data in wind farms[J]. Power System Protection and Control, 2015, 43(3): 38-45.

[9] BENCHEKROUN M, CHEVALLIER B, ZALC V, et al. The impact of missing data on heart rate variability features: a comparative study of interpolation methods for ambulatory health monitoring[J]. IRBM, 2023, 44(4): 1959-0318.

[10] MIAO X, GAO Y, CHEN G, et al. Processing incomplete k nearest neighbor search[J]. IEEE Transactions on Fuzzy Systems, 2016, 24(6): 1349-1363.

[11] 冯磊, 王石刚, 梁庆华. 基于 GAKNN 方法的配电站时间序列缺失数据补全方法[J]. 电力自动化设备, 2021, 41(12): 187-192.  
FENG Lei, WANG Shigang, LIANG Qinghua. Completion method for missing time series data of distribution station based on GAKNN method[J]. Electric Power Automation Equipment, 2021, 41(12): 187-192.

[12] 梅玉杰, 李勇, 周王峰, 等. 基于机器学习的配电网异常缺失数据动态清洗方法[J]. 电力系统保护与控制, 2023, 51(7): 158-169.  
MEI Yujie, LI Yong, ZHOU Wangfeng, et al. Dynamic data cleaning method of abnormal and missing data in a distribution network based on machine learning[J]. Power System Protection and Control, 2023, 51(7): 158-169.

[13] 刘志坚, 陶韵旭, 刘航, 等. 基于双通道生成对抗网络的城用电负荷缺失数据补全方法[J]. 电力系统自动化, 2024, 48(17): 161-170.  
LIU Zhijian, TAO Yunxu, LIU Hang, et al. Completion method for missing urban power load data based on double-channel generative adversarial networks[J]. Automation of Electric Power Systems, 2024, 48(17): 161-170.

[14] 徐东伟, 彭航, 商学天, 等. 基于图自编码-生成对抗网络的路网数据修复[J]. 交通运输系统工程与信息, 2021, 21(6): 33-41.  
XU Dongwei, PENG Hang, SHANG Xuetian, et al. Road network data repair based on graph autoencoder-generative adversarial network[J]. Journal of Transportation Systems

- Engineering and Information Technology, 2021, 21(6): 33-41.
- [15] 蒋栋年, 王仁杰. 基于 GAN 的软测量缺失数据生成方法研究[J]. 西北工业大学学报, 2024, 42(2): 344-352.  
JIANG Dongnian, WANG Renjie. Research on the generation method of missing data for soft measurement based on GAN[J]. Journal of Northwestern Polytechnical University, 2024, 42(2): 344-352.
- [16] 粟佳, 于洪. 基于条件生成对抗插补网络的双重判别器缺失值插补算法[J]. 计算机应用, 2024, 44(5): 1423-1427.  
SU Jia, YU Hong. Missing value imputation algorithm using dual discriminator based on conditional generative adversarial imputation network[J]. Journal of Computer Applications, 2024, 44(5): 1423-1427.
- [17] 崔阳阳, 赵洪山, 曲岳晗, 等. 基于残差 U 型网络的低压台区电力缺失数据补全方法[J]. 电力系统自动化, 2022, 46(9): 83-90.  
CUI Yangyang, ZHAO Hongshan, QU Yuehan, et al. Residual U-net based complementation method for missing electricity data of low-voltage stations[J]. Automation of Electric Power Systems, 2022, 46(9): 83-90.
- [18] ZHANG K, LI C, YANG Q. Trid-mae: a generic pre-trained model for multivariate time series with missing values[C] // Proceedings of the 32nd ACM International Conference on Information and Knowledge Management, October 21-25, 2023, Birmingham, UK: 3164-3173.
- [19] 郭凌旭, 王天昊, 黄盼, 等. 基于 MLSTM-CI 的配电系统多时刻量测缺失数据修复[J]. 山东电力技术, 2025, 52(8): 56-66.  
GUO Lingxu, WANG Tianhao, HUANG Pan, et al. Multi-moment missing measurement data reparation for power distribution system based on MLSTM-CI[J]. Shandong Electric Power, 2025, 52(8): 56-66.
- [20] 刘科研, 周方泽, 周晖, 等. 基于改进生成对抗网络的台区采集数据修复[J]. 电网技术, 2022, 46(8): 3231-3240.  
LIU Keyan, ZHOU Fangze, ZHOU Hui, et al. Missing data imputation in transformer district based on improved generative adversarial network[J]. Power System Technology, 2022, 46(8): 3231-3240.
- [21] 杨玉莲, 齐林海, 王红, 等. 基于生成对抗和双重语义感知的配电网量测数据缺失重构[J]. 电力系统自动化, 2020, 44(18): 46-54.  
YANG Yulian, QI Linhai, WANG Hong, et al. Reconstruction of missing measurement data in distribution network based on generative adversarial network and double semantic perception[J]. Automation of Electric Power Systems, 2020, 44(18): 46-54.
- [22] 殷豪, 丁伟锋, 陈顺, 等. 基于生成对抗网络和纵横交叉粒子群算法的光伏数据缺失重构方法[J]. 电网技术, 2021, 46(4): 1372-1381.  
YIN Hao, DING Weifeng, CHEN Shun, et al. Reconstruction method for missing data in photovoltaic based on generative adversarial network and crisscross particle swarm optimization algorithm[J]. Power System Technology, 2022, 46(4): 372-1381.
- [23] 李欢利, 郭立红, 陈涛, 等. 基于 PCHIP-LMD 的虹膜识别方法[J]. 光学精密工程, 2013, 21(1): 197-206.  
LI Huanli, GUO Lihong, CHEN Tao, et al. Iris recognition based on PCHIP-LMD[J]. Optics and Precision Engineering, 2013, 21(1): 197-206.
- [24] CAMPELLO R, MOULAVI D, ZIMEK A, et al. Hierarchical density estimates for data clustering, visualization, and outlier detection[J]. ACM Transactions on Knowledge Discovery from Data (TKDD), 2015(10): 1-51.
- [25] 王继业, 邓春宇, 郑亚芹, 等. 基于 HDBSCAN 动态跟踪客户用电行为模式[J]. 供用电, 2019, 36(1): 10-16.  
WANG Jiye, DENG Chunyu, ZHENG Yaqin, et al. Dynamic tracking of customer's load behavior pattern by HDBSCAN[J]. Distribution and Utilization, 2019, 36(1): 10-16.
- [26] GOODFELLOW I, POUGETABADIE J, MIRZA M, et al. GAN(generative adversarial nets)[J]. Journal of Japan Society for Fuzzy Theory and Intelligent Informatics, 2017: 177-177.
- [27] Laboratoire-Piment/TwInSolar\_consolidated\_data: a set of consolidated data for the microgrid of Terre Sainte campus (years 2021 and 2022)[EB/OL]. [https://github.com/Laboratoire-Piment/TwInSolar\\_consolidated\\_data](https://github.com/Laboratoire-Piment/TwInSolar_consolidated_data)
- [28] FOUMANI N, TAN C, WEBB G, et al. Improving position encoding of transformers for multivariate time series classification[J]. Data Mining and Knowledge Discovery, 2023, 38: 22-48.
- [29] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. Computer Vision and Pattern Recognition, 2015, 15(11): 122-129.
- [30] 刘仲民, 李耀龙, 胡文瑾. 融合混合空洞卷积和动态卷积的敦煌壁画修复[J]. 计算机工程与设计, 2025, 46(2): 595-602.  
LIU Zhongmin, LI Yaolong, HU Wenjing. Dunhuang mural inpainting combining hybrid dilated convolution and dynamic convolution[J]. Computer Engineering and Design, 2025, 46(2): 595-602.
- [31] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C] // Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, May 13-15, 2010, Sardinia, Italy: 249-256.
- [32] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification[C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile: 1026-1034.

收稿日期: 2025-07-24; 修回日期: 2025-10-20

作者简介:

王小龙(2000—), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用; E-mail: 935442689@qq.com

彭显刚(1964—), 男, 通信作者, 硕士, 教授, 研究方向为电力系统分析。E-mail: epwg@gdut.edu.cn

(编辑 石晋美)