

DOI:10.12158/j.2096-3203.2024.01.017

基于生成对抗 Transformer 的电力负荷数据异常检测

陆旦宏, 范文尧, 杨婷, 倪敏珏, 李思琦, 朱晓

(南京工程学院电力工程学院, 江苏 南京 211167)

摘要: 电力负荷异常数据将给电力系统规划、负荷预测以及用能分析等带来较大的负面影响, 因此亟须对负荷数据异常进行检测与识别。首先, 针对电力负荷数据异常分类、原因及其特征开展分析。其次, 改进传统 Transformer 编码器结构, 采用多头注意力层代替掩码多头注意力层, 同时移除前馈网络, 以提高模型对负荷时序序列的全局注意力。基于生成对抗网络 (generative adversarial networks, GAN) 生成器与判别器的博弈结构, 提出一种改进的 GAN-Transformer 模型, 以更好地捕捉趋势性特征并加速模型收敛。然后, 引入多阶段映射与训练方法, 综合焦点分数打分机制, 通过分阶段负荷序列重构帮助模型更好地提取负荷数据异常特征。最后, 算例分析结果表明, GAN-Transformer 模型在负荷数据异常检测精确率、召回率、 F_1 值以及训练时间方面均具有更优的性能, 验证了所提方法的有效性和优越性。文中研究工作作为基于深度学习进一步实现电力负荷数据异常分类与数据修复提供了有益参考。

关键词: 电力负荷数据; 数据异常检测; 生成对抗网络 (GAN)-Transformer; 多阶段训练与映射; 焦点分数; 序列重构
中图分类号: TM715 **文献标志码:** A **文章编号:** 2096-3203(2024)01-0157-08

0 引言

近年来, 电力系统在物联网和大数据等技术的推动下进入了电力大数据时代^[1]。其中, 电力负荷数据是对一定范围内的负荷对象进行用能大小、变化趋势及其分布特点的刻画与描述^[2], 丰富的电力负荷数据为电力系统制定决策夯实了数据基础。电力负荷受季节、天气、日类型、检修计划、生产生活及突发故障等多维因素影响, 具有周期性、趋势性及随机性等典型特点^[3-4]。由于电力负荷数据结构存在多元异构、数据体量大的问题, 在数据采集与传输过程中极易受系统故障、设备异常、传输误码及量测误差等因素影响, 导致负荷数据中掺杂了一些不易察觉的异常数据。这些异常数据将给系统规划、负荷预测及用能分析等带来负面影响^[5]。因此, 针对电力负荷数据异常进行检测与识别, 一是可及时发现和快速诊断故障与用户窃电等异常情况, 二是可及时阻止负荷异常数据继续扩散^[6], 防止电力系统规划因异常数据做出错误决策。

传统的数据异常检测方法可以分为 6 种类型, 主要包括基于分类^[7-9]、基于密度^[10-11]、基于聚类^[12-14]、基于统计^[15-16]、基于信息理论^[17] 以及基于频谱等异常检测方法。其中, 基于统计的方法往往假设数据为简单分布, 无法反映出真实数据的分布情况; 基于密度和基于聚类的方法无法有效提取时

序数据中的细部特征; 基于分类的模型则要求数据必须具备标签, 对数据质量要求高, 且某些特殊故障类型导致的数据异常不能满足标注需求。

由于电力负荷数据是一种典型的时序序列, 当前一些研究主要聚焦于利用深度学习的范式解决时序序列异常检测问题^[18-24]。文献[19]提出了基于自回归神经网络的无参数化动态阈值长短期记忆网络 (long short-term memory for natural language understanding with noisy data training, LSTM-NDT) 进行数据异常检测, 采用无监督训练方式, 对检测结果根据无参数化设定阈值进行异常判定, 但模型过度依赖局部特征, 忽略了长序列的全局特征。文献[20]基于长短期记忆循环神经网络架构, 提出了具有生成对抗网络的多元异常检测 (multiple anomaly detection using generative adversarial networks, MAD-GAN) 方法, 采用 GAN 的对抗生成机制对时间序列进行重构, 通过分离异常评分实现数据异常诊断。引入 GAN 训练机制后, 一定程度地提高了对时序序列分布特征的捕获能力。文献[21]提出了基于随机递归神经网络的 OmniAnomaly 多变量时间序列异常检测模型, 结合门控循环单元和变分自编码器刻画时序序列的局部特征依赖和随机性特征, 但模型复杂度过高, 将出现训练时间长和不易收敛的问题。针对用户窃电异常行为检测问题, 文献[22]提出了深度自编码器高斯混合模型 (deep auto-encoder Gaussian mixture model, DAGMM), 利用压缩网络提取数据潜在特征, 但由于压缩网络可能会引起特征丢失, 并不能较好地保留原始特征空间的拓

收稿日期: 2023-08-24; 修回日期: 2023-11-21

基金项目: 江苏省自然科学基金资助项目 (BK20210932); 江苏省产学研合作项目 (BY2022056)

扑,从而降低了数据异常检测的查全率。文献[23]提出了多尺度卷积循环编码器-解码器结构,构造特征矩阵编码与解码重构,对长可变的时序序列具有较好的泛化能力。已有研究表明,虽然Transformer的掩码多头注意力层能对时间趋势性进行一定程度的推理,但是难以提取负荷异常时刻或时段前后数据的相关性特征^[24]。总而言之,当前基于深度学习的数据异常检测方法研究主要致力于优化模型结构、设计异常诊断机制以及改进模型训练机制,以期在模型复杂度、训练难度、推理速度、异常检测精确率以及泛化能力上取得较好平衡。

考虑到不同负荷数据的异常时间尺度与变化趋势往往不同,即提取特征时既要关注异常持续时间又要关注突变程度。文中首先厘清电力负荷数据异常分类、原因及其特征,明确电力负荷数据异常检测技术需求。然后,为更好地捕捉负荷数据的趋势特征并提高异常检测的准确性,拟通过改进传统Transformer编码器结构,依托GAN生成器与判别器的博弈机制,提出一种改进的GAN-Transformer模型。最后,通过算例对所提电力负荷数据异常检测模型的有效性与其优越性开展分析验证。

1 电力负荷数据异常分类

电力负荷包括发电负荷、供电负荷以及用电负荷,通常具有周期性、自相关性与趋势性等典型特征。受极端天气、生产生活以及设备故障等不确定性因素影响,电力负荷又呈现出随机性、波动性及突变性等特征^[25],电力负荷数据往往会出现异常跳变,表现为波动异常与极值异常,如图1所示。其中,横坐标为每隔10 min采集一次的数据点。

波动异常负荷曲线表现为短时间内出现大量毛刺且波动频繁,与正常的负荷波动规律相比有显著跳变。极值异常负荷曲线表现为负荷数据极值异常,在一定时间内(持续时间通常为分钟级)出现负荷尖峰、谷值或较大的峰谷差,破坏了曲线相似性与周期性。其中,波动异常的负荷数据通常由内部噪声或外界干扰引起,易在极端天气以及人为操作失误的场景下产生;极值异常的负荷数据通常由采集数据在某时刻缺损引起,易在切负荷停电、设备(变压器、电缆、保护装置等)故障、数据采集与传输干扰以及用户窃电的场景下产生。

2 GAN-Transformer 模型原理

2.1 Transformer 模型

首先,依靠Transformer架构的自注意力机制提




图1 电力负荷数据异常示意

Fig.1 Anomaly schematic of power load data

取负荷数据中各元素的时间相关性。Transformer由N个编码器和解码器组合而成,单个编码器与解码器的结构如图2所示。其中, h_1, h_2, h_3 为多头注意力层和掩码多头注意力层的多个特征输入。

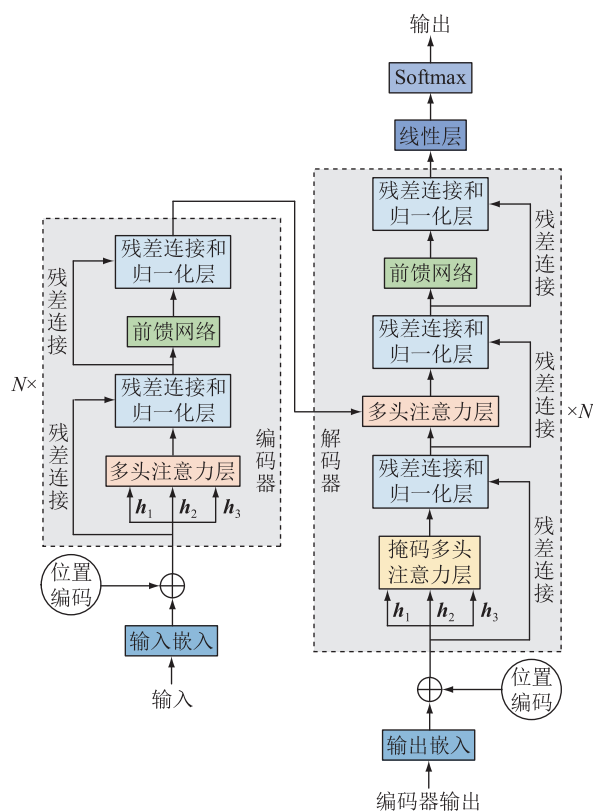


图2 Transformer 模型结构

Fig.2 Structure of Transformer model

解码器采用掩码多头注意力层,确保解码器只关注 $t-1$ 时刻数据对 t 时刻数据的特征映射,而不会引入 $t+1$ 时刻的数据信息。与解码器相比,编码器主要由多头注意力层和前馈网络构成,多头注意力层可以使模型同时关注多个局部特征。为避免网络加深引起的序列过拟合问题,模型中引入了残差连接。

Transformer 模型的多头注意力层可针对位置编码矩阵使用多组 $W_{Q,i}$ 、 $W_{K,i}$ 、 $W_{V,i}$ 得到多组 Q 矩阵、 K 矩阵、 V 矩阵,从而对输入信息进行高低权重分配。 $W_{Q,i}$ 、 $W_{K,i}$ 、 $W_{V,i}$ 为多头映射过程中的权重矩阵,其中 $W_{Q,i} \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 、 $W_{K,i} \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 、 $W_{V,i} \in \mathbb{R}^{d_{\text{model}} \times d_v}$, $i \in \{1, 2, 3\}$ 为注意力机制头的数量,且 $d_k = d_v = d_{\text{model}}/3 = 64$ 。

每组 Q 矩阵、 K 矩阵、 V 矩阵通过不同的线性变换分别得到一个 Z 矩阵,将得到的多个 Z 矩阵进行拼接。多头注意力层的计算过程可表示为:

$$\begin{cases} \mathbf{h}_i = f_{\text{Attention}}(\mathbf{Q}W_{Q,i}, \mathbf{K}W_{K,i}, \mathbf{V}W_{V,i}) \\ f_{\text{MultiHead}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = f_{\text{Concat}}(\mathbf{h}_1, \mathbf{h}_2, \mathbf{h}_3) \mathbf{W}_0 \end{cases} \quad (1)$$

式中: $f_{\text{Attention}}(\cdot)$ 为多头映射过程函数; $f_{\text{MultiHead}}(\cdot)$ 、 $f_{\text{Concat}}(\cdot)$ 为多头注意力层运算过程函数; $\mathbf{W}_0 \in \mathbb{R}^{d_v \times d_{\text{model}}}$ 为参与多头注意力层运算过程的参数向量。

2.2 GAN-Transformer 模型

考虑区域电力系统中存在多个节点,采集的数据为多变量时间序列。定义 \mathbf{x} 为电力系统中节点采集的负荷数据, $\mathbf{W} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t\}$, $\mathbf{x}_t \in \mathbb{R}^m$, $t = 1, 2, \dots, N$, \mathbf{x} 为大小为 m 的向量,即该序列有 m 个节点特征。GAN-Transformer 模型结构如图 3 所示。

生成器 1 用于生成包含负荷数据异常焦点分数与位置编码信息特征的重构序列。依托 Transformer 生成器架构,将焦点分数与位置编码信息作为输

入,输出为输入序列的重构数据 $I_{1,3}$ 。在生成器 1 的正向传播过程中,焦点分数初始值以零向量形式与位置编码信息 I_1 共同作为多头注意力层的输入,输出记为 $I_{1,1}$;再将 I_1 与 $I_{1,1}$ 共同经过残差连接和归一化层,输出记为 $I_{1,2}$;输入 $I_{1,2}$ 依次至前馈网络、第二个残差连接和归一化层,经过 ReLU 激活函数线性变换以及残差连接操作输出 $I_{1,3}$ 。将生成器 1 表示为:

$$\begin{cases} I_{1,1} = f_{\text{MH}}(I_1, I_1, I_1) \\ I_{1,2} = f_{\text{LayerNorm}}(I_1 + I_{1,1}) \\ I_{1,3} = f_{\text{LayerNorm}}(I_{1,2} + f_{\text{FFN}}(I_{1,2})) \end{cases} \quad (2)$$

式中: $f_{\text{MH}}(I_1, I_1, I_1)$ 为对拼接后的输入矩阵 I_1 进行多头注意力操作; $f_{\text{FFN}}(I_{1,2})$ 为对输入矩阵 $I_{1,2}$ 进行前馈网络操作; $f_{\text{LayerNorm}}(\cdot)$ 为对每一层的输入值进行归一化处理。

生成器 2 用于重构输入电力负荷序列。在生成器 2 的正向传播过程中,将电力负荷序列与位置编码信息 I_2 作为输入,通过首个多头注意力层,输出记为 $I_{2,1}$;将 I_2 与 $I_{2,1}$ 输入第一个残差连接和归一化层,输出记为 $I_{2,2}$; $I_{2,2}$ 经过第二层的多头注意力层以及残差连接和归一化层的操作后,输出记为 $I_{2,3}$ 。将生成器 2 表示为:

$$\begin{cases} I_{2,1} = f_{\text{MH}}(I_2, I_2, I_2) \\ I_{2,2} = f_{\text{LayerNorm}}(I_2 + I_{2,1}) \\ I_{2,3} = f_{\text{LayerNorm}}(I_{2,2} + f_{\text{MH}}(I_{2,2}, I_{2,2}, I_{2,2})) \end{cases} \quad (3)$$

判别器 1 与判别器 2 由位置前馈网络和 Sigmoid 激活函数构成。第一阶段的判别器 1 和判别器 2 分别表示为:

$$\begin{cases} O_1 = f_{\text{Sigmoid}}(f_{\text{FFN}}(I_{1,3})) \\ \hat{W} = f_{\text{Sigmoid}}(f_{\text{FFN}}(I_{2,3})) \end{cases} \quad (4)$$

第二阶段判别器 2 表示为:

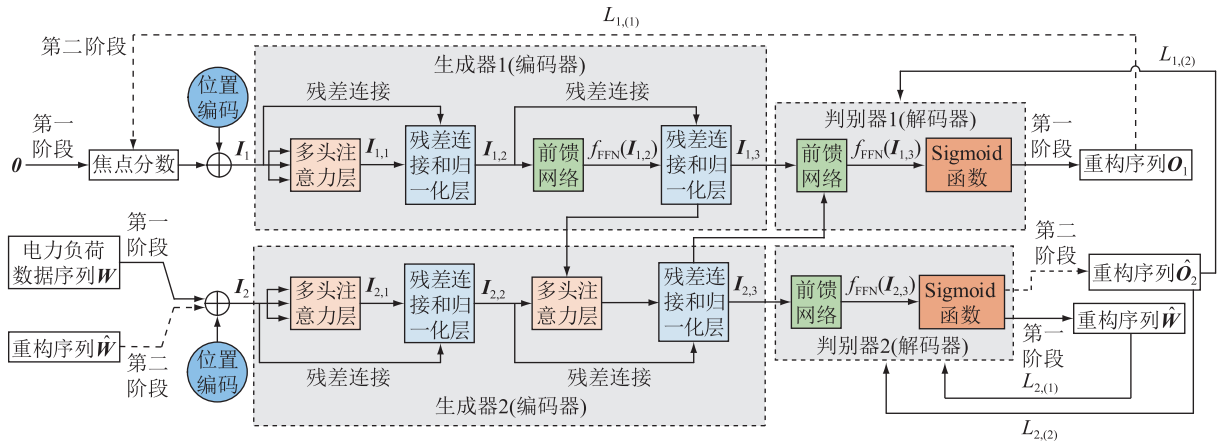


图 3 GAN-Transformer 模型结构

Fig.3 Structure of GAN-Transformer model

$$\hat{\mathbf{O}}_2 = f_{\text{Sigmoid}}(f_{\text{FFN}}(\mathbf{I}_{2,3})) \quad (5)$$

式中： \mathbf{O}_1 为第一阶段判别器 1 输出结果； $\hat{\mathbf{W}}$ 为第一阶段判别器 2 输出结果； $\hat{\mathbf{O}}_2$ 为第二阶段判别器 2 输出结果； $f_{\text{Sigmoid}}(\cdot)$ 为激活函数。

2.2.1 分阶段映射与训练

运用分阶段多次映射的思想对模型进行训练。以两阶段映射为例，将第一阶段映射的输出作为第二阶段的输入。为得到初始重构负荷序列，第一阶段定义为模型映射阶段，将焦点分数初始值 θ 经过位置编码后输入至生成器 1 中，生成器 1 与生成器 2 的输出共同作为判别器 1 的输入，判别器 1 输出重构序列 \mathbf{O}_1 。同时将电力负荷历史数据序列 \mathbf{W} 经过位置编码后输入至生成器 2 中，生成器 1 的输出将作为生成器 2 多头注意力层的部分输入，生成器 2 的输出作为判别器 2 的输入，此时判别器 2 的输出结果对应为第一阶段重构序列 $\hat{\mathbf{W}}$ 。

为得到更优的重构负荷序列，第二阶段定义为模型训练与重映射阶段。基于第一阶段映射，模型完成对抗训练后再进行重映射。将第一阶段中判别器 1 的重构损失 $L_{1,(1)}$ 作为第二阶段的焦点分数，经过位置编码后再次输入至生成器 1。同时将第一阶段重构序列 $\hat{\mathbf{W}}$ 经过位置编码后再次输入至生成器 2，此时判别器 2 的输出结果为第二阶段重构序列 $\hat{\mathbf{O}}_2$ ，将其作为最终的负荷时序序列重构结果。

2.2.2 损失函数

模型在第一阶段的目标是生成和输入负荷数据分布一致的重构序列。将重构损失结果作为焦点分数，促使生成器关注趋势异常的子序列。

定义第一阶段判别器 1 和判别器 2 的重构损失函数为 $L_{1,(1)}$ 和 $L_{2,(1)}$ 分别为：

$$\begin{cases} L_{1,(1)} = \|\mathbf{O}_1 - \mathbf{W}\|_2 \\ L_{2,(1)} = \|\hat{\mathbf{W}} - \mathbf{W}\|_2 \end{cases} \quad (6)$$

模型在第二阶段进行模型训练与重映射，定义第二阶段判别器 1 和判别器 2 的重构损失函数为 $L_{1,(2)}$ 和 $L_{2,(2)}$ 分别为：

$$\begin{cases} L_{1,(2)} = + \|\hat{\mathbf{O}}_2 - \mathbf{W}\|_2 \\ L_{2,(2)} = - \|\hat{\mathbf{O}}_2 - \mathbf{W}\|_2 \end{cases} \quad (7)$$

将第一阶段和第二阶段的判别器 1 和判别器 2 的损失函数相结合，得出模型的整体损失函数 L_1 和 L_2 分别为：

$$\begin{cases} L_1 = \varepsilon^{-n} \|\mathbf{O}_1 - \mathbf{W}\|_2 + (1 - \varepsilon^{-n}) \|\hat{\mathbf{O}}_2 - \mathbf{W}\|_2 \\ L_2 = \varepsilon^{-n} \|\hat{\mathbf{W}} - \mathbf{W}\|_2 - (1 - \varepsilon^{-n}) \|\hat{\mathbf{O}}_2 - \mathbf{W}\|_2 \end{cases} \quad (8)$$

式中： n 为模型训练次数； ε 为超参数，一般取值接近 1。

2.2.3 异常数据检测机制

为了准确识别输入负荷数据中的异常点，将输入负荷数据与模型第一阶段重构序列 $\hat{\mathbf{W}}$ 进行对比，引入异常得分和异常诊断标签用于检测异常数据。定义异常得分为两阶段重构序列和输入数据的 L2 范数之和，异常得分越高表示此处负荷数据异常偏差越大。定义异常诊断标签为某个时间点的异常分数，该时间点判断依据为异常分数大于设置阈值。使用峰值超过阈值 (peaks over threshold, POT) 的方法来自动和动态地选择阈值。

$$\begin{cases} s_t = \frac{1}{2} \|\mathbf{O}_1 - \hat{\mathbf{W}}\|_2 + \frac{1}{2} \|\hat{\mathbf{O}}_2 - \hat{\mathbf{W}}\|_2 \\ y_t = 1 \quad s_t \geq f_{\text{POT}}(s_t) \end{cases} \quad (9)$$

式中： s_t 为异常得分； f_{POT} 为使用 POT 方法设置的阈值； y_t 为异常诊断标签， $y_t = 1$ 为 t 时刻数据的异常标签， $y_t = 0$ 为 t 时刻数据的正常标签。

3 电力系统负荷数据异常检测实现

3.1 实现流程

基于 GAN-Transformer 模型的电力系统负荷异常检测的实现流程如图 4 所示，主要步骤为：

- (1) 获取包含丰富异常特征的典型电力系统负荷历史数据，且将采集的电力负荷历史数据分为训练样本集和测试样本集，对训练样本进行归一化处理；
- (2) 将训练样本集作为模型的输入，设置超参数与训练次数，完成模型训练；
- (3) 将测试样本集作为模型的输入，将模型输出结果根据异常检测机制进行异常诊断，判断是否为异常数据；
- (4) 通过质量评估对测试结果与模型检测性能进行综合评价分析。




图 4 基于 GAN-Transformer 电力负荷异常检测流程
Fig.4 Power load anomaly detection process based on GAN-Transformer

3.2 检测性能评估指标

使用精确率 P 、召回率 R 和 F_1 值来综合评估 GAN-Transformer 模型的数据异常检测性能：

$$P = \frac{T_p}{T_p + F_p} \quad (10)$$

$$R = \frac{T_p}{T_p + F_N} \quad (11)$$

$$F_1 = \frac{2PR}{P + R} \quad (12)$$

式中: T_p 为实际检测出的异常样本数量(检测值为1,真实值为1); F_p 为检测为异常但实际非异常的样本数量(检测值为1,真实值为0); F_N 为未被检测出的异常样本数量(检测值为0,真实值为1)。

4 电力系统负荷数据异常检测实验分析

4.1 数据预处理

对负荷数据集进行归一化处理。采用最大最小归一化法,将输入的训练样本数据与输出的电力负荷重构数据均按等比例缩放,转换至 $[0,1]$ 的无量纲归一化值。

$$\mathbf{x}_i^* = \frac{\mathbf{x}_i - \min(\mathbf{x})}{\max(\mathbf{x}) - \min(\mathbf{x}) + \epsilon'} \quad (13)$$

式中: \mathbf{x}_i^* 为 t 时刻的训练样本数据 \mathbf{x}_i 进行归一化后的向量; $\min(\cdot)$ 、 $\max(\cdot)$ 分别为时间序列中的最小值和最大值函数; ϵ' 为一个常数向量。

4.2 检测结果及分析评估

为验证 GAN-Transformer 模型在电力负荷数据异常检测方面的有效性,基于 Python 3.8 解释器、Pycharm 2022.2 编译环境、i5-12400F 计算机处理器、32 G 内存以及 Windows 10 操作系统搭建实验环境。数据集来源于某供电台区历史供电负荷数据与用电负荷数据,数据采集时间间隔为 30 s,时间跨度为 90 d,覆盖波动异常与极值异常 2 种典型特征。按照 7:3 的比例随机分为训练集和测试集。模型训练结束后,从测试集中随机抽取 3 d 的数据进行异常检测结果分析,如图 5、图 6 所示。

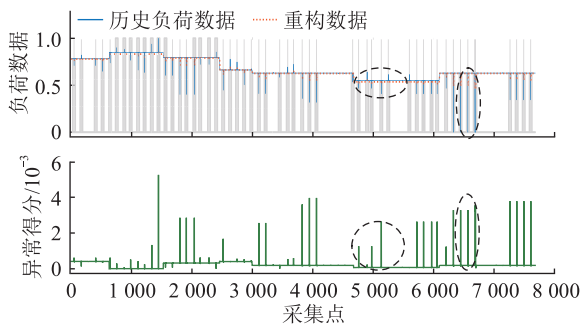


图 5 供电负荷数据异常检测结果

Fig.5 Power load data anomaly detection results

图 5 与图 6 中横坐标均为按等间隔时间 30 s 采集的电力负荷数据量,纵坐标分别为 GAN-

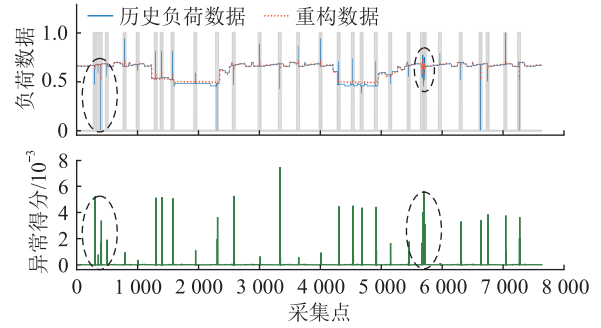



图 6 用电负荷数据异常检测结果


Fig.6 Electricity load data anomaly detection results

Transformer 模型电力负荷数据归一化后区间为 $[0,1]$ 的重构输出与异常数据诊断得分。为便于理解,图 5 中采用灰色阴影表示负荷异常出现的区域。异常得分曲线下端由不同阶段的 POT 组成,得分高于阈值的柱状曲线表示该点可能存在负荷异常,同时柱状曲线的幅值越大表示异常得分越高。

为深入分析图 5 所示的供电负荷数据异常检测结果,以负荷数据极值异常为例,放大图 5 的局部信息,得出重构电力数据与历史负荷数据的明显对比结果,如图 7 所示,可知 GAN-Transformer 能够准确检测识别出供电负荷数据中的极值异常。



(a) 极值异常1



(b) 极值异常2

图 7 供电负荷数据异常检测结果细节

Fig.7 Details of power load data anomaly detection results

为深入分析图 6 所示的用电负荷数据异常检测结果,以负荷数据极值异常为例,放大图 6 中的局部历史负荷数据与重构负荷数据信息,得到图 8(a)所示的极值异常检测结果明细图;以负荷数据波动异常为例,放大图 6 中的局部历史负荷数据与重构负荷数据信息,得到图 8(b)所示的波动异常检测结果明细图。图 8 中,由判别器 2 生成的重构数据能够较好地捕捉给定电力负荷曲线变化特征。无论是历史用电负荷数据与模型重构序列,还是异常得分结果,GAN-Transformer 均能够准确检测识别出用电负荷数据中的极值异常与波动异常。




图 8 用电负荷数据异常检测结果细节
Fig.8 Details of electricity load data anomaly detection results

4.3 算法对比分析

为了验证 GAN-Transformer 模型对负荷数据异常检测的优越性,将其与 OmniAnomaly、LSTM-NDT、MAD-GAN、DAGMM、无监督异常检测(unsupervised anomaly detection, USAD)以及 Transformer 等对照模型进行异常检测对比实验分析,且各模型训练次数均设置为 500 次。表 1 和表 2 分别为供电负荷数据和用电负荷数据在不同模型下的检测结果。

分析供电负荷数据异常检测结果,表 1 中 GAN-Transformer 模型的检测精确率为 0.949 2, 相比其他

表 1 不同模型训练供电负荷数据的对比实验结果

Table 1 Comparative experimental results of power load data from different model training

模型	P	R	F_1	单次训练时间/s
OmniAnomaly	0.473 5	0.663 4	0.552 1	10.54
LSTM-NDT	0.845 4	0.984 6	0.909 7	3.11
MAD-GAN	0.851 9	0.959 9	0.902 6	10.30
DAGMM	0.824 3	0.999 9	0.903 7	7.00
USAD	0.840 9	0.999 9	0.913 5	7.90
Transformer	0.746 9	0.863 5	0.801 0	6.00
GAN-Transformer	0.949 2	0.938 4	0.943 7	2.30

表 2 不同模型训练用电负荷数据的对比实验结果

Table 2 Comparative experimental results of electricity load data from different model training

模型	P	R	F_1	单次训练时间/s
OmniAnomaly	0.796 5	0.852 3	0.823 4	10.54
LSTM-NDT	0.501 3	0.655 1	0.568 0	3.11
MAD-GAN	0.896 7	0.867 7	0.882 0	12.30
DAGMM	0.868 2	0.979 9	0.920 6	7.00
USAD	0.926 1	0.919 9	0.922 9	7.90
Transformer	0.765 2	0.869 9	0.814 1	6.00
GAN-Transformer	0.976 2	0.926 4	0.950 6	2.30

模型精确率提高了 10%~20%。GAN-Transformer 模型的召回率为 0.938 4, 略低于其他模型, 表明其对异常数据的查全率较低, 进而表明模型的异常误检率也较低。针对用电负荷数据检测与识别, 表 2 中 GAN-Transformer 模型的检测精确率为 0.976 2, 相比于其他模型仍然具有优势。此时, GAN-Transformer 模型的召回率为 0.926 4, 与其他模型相比拥有相似的查全率。综合分析精确率和召回率结果, 表 1 中 GAN-Transformer 模型的 F_1 值为 0.943 7, 表 2 中 GAN-Transformer 模型的 F_1 值为 0.950 6, 均明显高于对照模型且最接近 1。分析不同模型的训练时间可以得出, GAN-Transformer 模型在训练次数相同、训练时间减少了 70% 的情况下, 异常检测精确率明显提升, 模型综合表现更优。

5 结语

针对电力负荷数据异常检测的相关问题, 首先将电力负荷数据异常按照波动异常与极值异常进行合理分类, 并分析不同异常现象的负荷数据; 其次, 在 Transformer 与 GAN 的框架下提出了一种基于 GAN-Transformer 的改进模型, 给出了模型的详细框架和生成器、判别器以及损失函数的数学表达; 然后, 将特征映射与训练过程分为 2 个阶段, 将第一阶段的输出作为第二阶段的输入, 促使模型所得到

的重构负荷序列能更好地刻画电力负荷数据趋势变化特征,并通过设计焦点分数打分机制实现负荷数据异常诊断。算例分析结果表明,与对照模型相比,GAN-Transformer 模型在负荷数据异常检测精确率、召回率、 F_1 值以及训练时间方面均具有更优的性能,从而表明了所提模型的有效性和优越性。

虽然文中所提模型对电力负荷时序序列的检测准确性有一定的改进和提高,但针对电力负荷多变量时序序列检测、模型推理速度以及泛化能力尚待进一步深入研究。文中的研究作为进一步基于深度学习实现电力负荷数据异常分类与异常数据修复提供了一定的理论与实践支撑。

参考文献:

- [1] 于金镒. 向建设“具有卓越竞争力的世界一流能源互联网企业”目标奋进[J]. 国家电网,2018(8):54-55.
YU Jinyi. Strive for the goal of building a world-class energy Internet enterprise with excellent competitiveness[J]. State Grid, 2018(8):54-55.
- [2] 林昱旻,胡嘉铭,戴伟力,等. 基于改进 K-均值联合 SVDD 的电力数据异常检测方法[J]. 电力电容器与无功补偿,2023,44(5):99-107.
LIN Yuhuan, HU Jiaming, DAI Weili, et al. Power data abnormality detection method based on improved K-means and SVDD [J]. Power Capacitor & Reactive Power Compensation, 2023, 44(5):99-107.
- [3] 董骁翀,张妹,李焱,等. 电力系统中时序场景生成和约简方法研究综述[J]. 电网技术,2023,47(2):709-721.
DONG Xiaochong, ZHANG Shu, LI Ye, et al. Review of power system temporal scenario generation and reduction methods[J]. Power System Technology, 2023, 47(2):709-721.
- [4] 马一杰,陈君,刘松. 基于长短时记忆网络的电力负荷异常检测[J]. 云南大学学报(自然科学版),2020,42(S2):55-59.
MA Yijie, CHEN Jun, LIU Song. Power load abnormal detection based on long short-term memory[J]. Journal of Yunnan University (Natural Sciences Edition), 2020, 42(S2):55-59.
- [5] QIU X H, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting[J]. Applied Soft Computing, 2017, 54:246-255.
- [6] 白开峰,赵宏斌,张芸,等. 电网异常业务数据检测方法综述[J]. 计算机与现代化,2023(3):79-83,89.
BAI Kaifeng, ZHAO Hongbin, ZHANG Yun, et al. Review of abnormal service data detection methods in power grid[J]. Computer and Modernization, 2023(3):79-83,89.
- [7] 周捷,严建峰,杨璐,等. LSTM 模型集成方法在客户流失预测中的应用[J]. 计算机应用与软件,2019,36(11):39-46.
ZHOU Jie, YAN Jianfeng, YANG Lu, et al. Application of LSTM ensemble method in customer churn prediction[J]. Computer Applications and Software, 2019, 36(11):39-46.
- [8] SAEED, MUSTAFA, SHEIKH, et al. Ensemble bagged tree based classification for reducing non-technical losses in Multan electric power company of Pakistan [J]. Electronics, 2019, 8(8):860.
- [9] HU L J, LIU K Y, LIN Z, et al. An abnormal state detection method for power distribution network based on big data technology [C]//2018 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC). Zhengzhou, China. IEEE, 2019:169-1694.
- [10] SALEHI M, LECKIE C, BEZDEK J C, et al. Fast memory efficient local outlier detection in data streams[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(12):3246-3260.
- [11] BROWN J P, ROBERTS R G, WELSH C M, et al. Nearest neighbor anomaly detector for passively augmented LADAR [C]//2018 IEEE Research and Applications of Photonics In Defense Conference (RAPID). Miramar Beach, FL, USA. IEEE, 2018:1-4.
- [12] 金晟,苏盛,薛阳,等. 数据驱动窃电检测方法综述与低误报率研究展望[J]. 电力系统自动化,2022,46(1):3-14.
JIN Sheng, SU Sheng, XUE Yang, et al. Review on data-driven based electricity theft detection method and research prospect for low false positive rate[J]. Automation of Electric Power Systems, 2022, 46(1):3-14.
- [13] 肖勇,郑楷洪,余忠忠,等. 基于三次指数平滑模型与 DBSCAN 聚类的电量数据异常检测[J]. 电网技术,2020,44(3):1099-1104.
XIAO Yong, ZHENG Kaihong, YU Zhongzhong, et al. Power data anomaly detection based on holt-winters model and DBSCAN clustering[J]. Power System Technology, 2020, 44(3):1099-1104.
- [14] 陈启鑫,郑可迪,康重庆,等. 异常用电的检测方法:评述与展望[J]. 电力系统自动化,2018,42(17):189-199.
CHEN Qixin, ZHENG Kedi, KANG Chongqing, et al. Detection methods of abnormal electricity consumption behaviors: review and prospect[J]. Automation of Electric Power Systems, 2018, 42(17):189-199.
- [15] 卓琳,赵厚宇,詹思延. 异常检测方法及其应用综述[J]. 计算机应用研究,2020,37(S1):9-15.
ZHUO Lin, ZHAO Houyu, ZHAN Siyan. Overview of anomaly detection methods and applications[J]. Application Research of Computers, 2020, 37(S1):9-15.
- [16] KOLA SUJATHA P, YUVARANI S. Anomaly detection in video using Gaussian model and recurrent neural network [C]//2018 Tenth International Conference on Advanced Computing (ICoAC). Chennai, India. IEEE, 2019:202-207.
- [17] 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, United Kingdom. New York: ACM, 2018:387-395.

- [18] 庞传军,张波,余建明. 基于 LSTM 循环神经网络的短期电力负荷预测[J]. 电力工程技术,2021,40(1):175-180,194. PANG Chuanjun,ZHANG Bo,YU Jianming. Short-term power load forecasting based on LSTM recurrent neural network[J]. Electric Power Engineering Technology, 2021, 40(1): 175-180,194.
- [19] 陈磊,秦凯,郝矿荣. 基于集成 LSTM-AE 的时间序列异常检测方法[J]. 华中科技大学学报(自然科学版),2021,49(11):35-40. CHEN Lei,QIN Kai,HAO Kuangrong. Time series anomaly detection method based on integrated LSTM-AE[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition),2021,49(11):35-40.
- [20] LI D,CHEN D C,JIN B H,et al. MAD-GAN:multivariate anomaly detection for time series data with generative adversarial networks[C]//TETKO I,K URKOVÁ V,KARPOV P,et al. International Conference on Artificial Neural Networks. Cham;Springer,2019:703-716.
- [21] SU Y,ZHAO Y J,NIU C H,et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage,AK,USA. New York;ACM,2019:2828-2837.
- [22] 刘钊瑞,高云鹏,郭建波,等. 基于深度自编码器高斯混合模型的窃电行为检测[J]. 电力系统保护与控制,2022,50(18):92-102. LIU Zhaorui,GAO Yunpeng,GUO Jianbo,et al. Abnormal detection of electricity theft using a deep auto-encoder Gaussian mixture model [J]. Power System Protection and Control, 2022,50(18):92-102.
- [23] ZHANG C X,SONG D J,CHEN Y C,et al. A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data[J]. Proceedings of the AAAI Conference on Artificial Intelligence,2019,33(1):1409-1416.
- [24] XU J H,WU H X,WANG J M,et al. Anomaly transformer: time series anomaly detection with association discrepancy [EB/OL].[2023-04-20]. <https://arxiv.org/abs/2110.02642.pdf>.
- [25] 杨雯,尹康涌,鲍奕宇,等. 基于深度置信网络的电网故障类型辨识[J]. 电力工程技术,2021,40(2):169-177. YANG Wen,YIN Kangyong,BAO Yiyu,et al. Fault types identification of power grid based on deep belief network[J]. Electric Power Engineering Technology,2021,40(2):169-177.

作者简介:



陆旦宏

陆旦宏(1978),男,博士,教授,研究方向为新能源与智能电网(E-mail:ludh@njit.edu.cn);

范文尧(1999),男,硕士在读,研究方向为深度学习在配电网管控中的应用;

杨婷(1986),女,硕士,工程师,研究方向为机器学习在智能电网中的应用。

Anomaly detection of power load data based on Transformer and generative adversarial networks

LU Danhong, FAN Wenyao, YANG Ting, NI Minjue, LI Siqi, ZHU Xiao

(School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: Power system planning, load forecasting, and energy utilization analysis are significantly impacted by power load anomalies, necessitating prompt detection and identification. Firstly, the abnormal classification, causes, and characteristics of power load data are analyzed. Secondly, it enhances the traditional Transformer encoder structure by replacing the mask multi-header attention layer with the multi-header attention layer and eliminating the feedforward network. These improvements aim to enhance the model's global attention to the load sequence. To capture trend characteristics more effectively and expedite convergence, an improved generative adversarial networks (GAN)-Transformer model is proposed based on the generator and discriminator game structure of traditional GAN. Additionally, a multi-stage mapping and training approach along with an integrated focus score scoring mechanism are introduced. These techniques facilitate phased load sequence reconstruction, enabling the model to better extract anomalous features of the load data. Finally, through an analysis of an arithmetic example, the results demonstrate that the GAN-Transformer model outperforms in terms of load data anomaly detection accuracy, recall, F_1 value, and training time. These results validate the effectiveness and superiority of the proposed method. The findings of this research provide valuable insights for advancements in power load data anomaly classification and data repair based on deep learning.

Keywords: power load data; data anomaly detection; generative adversarial networks (GAN)-Transformer; multi-stage training and mapping; focus score; sequence refactoring

(编辑 陆海霞)