

万静意, 艾庆忠, 曾辉, 等. 基于混合生成对抗网络的核动力时序数据异常检测方法研究[J]. 智能计算机与应用, 2025, 15(5): 111-116. DOI: 10.20169/j.issn.2095-2163.24122403

基于混合生成对抗网络的核动力时序数据异常检测方法研究

万静意^{1,2}, 艾庆忠^{1,2}, 曾辉^{1,2}, 欧阳泽宇^{1,2}, 唐雷^{1,2}, 赵欣^{1,2}

(1 中国核动力研究设计院 核反应堆技术全国重点实验室, 成都 610213; 2 中国核动力研究设计院, 成都 610213)

摘要: 为利用核动力系统产生的大量时序数据, 自动、高效检测出系统动态运行过程中存在的各类异常, 本研究提出了一种面向核动力系统多元时序数据的无监督异常检测方法 NadGAN, 以提高微小异常和新异常的识别率, 避免其发展为严重事故。利用门控循环单元 (GRU) 作为生成对抗网络 (GAN) 中生成器和判别器的基础模型, 提取时间依赖关系, 通过对抗训练学习正常数据特征分布。在异常检测阶段, 采用自适应阈值方法综合考虑判别误差和重构误差进行异常判定, 避免手动调参。在 6 个仿真数据集上与 4 种基线方法进行对比实验, 结果表明 NadGAN 性能优于其他对比方法, 证明了将所提出方法运用于核动力系统异常检测的有效性和可行性。

关键词: 核动力系统; 多元时序数据; 异常检测; 生成对抗网络; 门控循环单元

中图分类号: TP309

文献标志码: A

文章编号: 2095-2163(2025)05-0111-06

Research on an anomaly detection method of nuclear power time series data based on hybrid Generative Adversarial Network

WAN Jingyi^{1,2}, AI Qingzhong^{1,2}, ZENG Hui^{1,2}, OUYANG Zeyu^{1,2}, TANG Lei^{1,2}, ZHAO Xin^{1,2}

(1 National Key Laboratory of Nuclear Reactor Technology, Nuclear Power Institute of China, Chengdu 610213, China;

2 Nuclear Power Institute of China, Chengdu 610213, China)

Abstract: To automatically and efficiently detect various abnormalities of the nuclear power system by utilizing the abundant time series data from nuclear power system, this study proposes an unsupervised anomaly detection method (NadGAN) based on nuclear power multivariate time series data. It aims to improve the identification accuracy of both minute and novel anomalies, and avoid them from developing into serious accidents. NadGAN applies Gated Recurrent Unit (GRU) as the fundamental model for both the generator and discriminator in a Generative Adversarial Network (GAN) framework, which is able to extract temporal dependencies and learn the feature distribution of normal data through adversarial training. In the anomaly detection stage, an adaptive thresholding approach is adopted to comprehensively consider the discriminative error and reconstruction error for anomaly identification without manual parameter tuning. Comparative experiments with four baseline methods on six simulated datasets demonstrate that NadGAN outperforms other methods, which further validates the effectiveness and feasibility of applying the proposed method for anomaly detection in nuclear power systems.

Key words: nuclear power system; multivariate time series data; anomaly detection; Generative Adversarial Network; gated recurrent unit

0 引言

核动力系统是由多个部件和子系统组成的复杂系统, 监控参数众多且存在相互关联, 在长期运行过

程中, 关键系统和装置可能会出现不容易被操作人员发现的微小异常以及未进行标注的新异常, 如果能尽早发现并及时采取措施, 可避免严重事故的发生。通过分析来自核动力系统不同传感器监控参数

基金项目: 四川省自然科学基金(23NSFSC2873)。

作者简介: 万静意(1997—), 女, 助理工程师, 主要研究方向: 核反应堆系统软件, 时空大数据分析 with 存储。Email: jingyiwan123@163.com; 艾庆忠(1995—), 男, 博士, 工程师, 主要研究方向: 机器学习, 数据分析; 曾辉(1972—), 男, 研究员级高级工程师, 主要研究方向: 大数据系统, 高性能计算; 欧阳泽宇(1997—), 男, 工程师, 主要研究方向: 先进核能系统研发; 唐雷(1984—), 男, 高级工程师, 主要研究方向: 反应堆安全分析, 核能与核技术工程; 赵欣(1980—), 男, 高级工程师, 主要研究方向: 核反应堆系统软件。

收稿日期: 2024-12-24

组成的多元时间序列数据,自动识别出系统存在的各类异常,对于提高异常检测速度和准确性、保证系统正常运行具有重要意义。

随着人工智能和物联网技术^[1]的快速发展,采用机器学习或深度学习框架构建异常检测模型已成为主流^[2]。其中,基于数据驱动的异常和故障检测方法在核能领域逐渐得到广泛研究,现有研究利用包括支持向量机(SVM)^[3]、径向基神经网络(RBF)^[4]、深度信念网络(DBN)^[5]、卷积神经网络(CNN)^[6]、长短期记忆网络(LSTM)^[7]、核主成分分析(KPCA)^[8]等主流模型算法学习异常数据特征,从而识别不同异常种类。由于在实际应用中缺乏异常数据样本及其对应的标签,上述方法能检测出的异常类型有限,对于未出现在样本数据中的新异常将无法进行有效识别。为解决这一问题,无监督的时序数据异常检测方法被提出,主要可分为基于近似^[9]、基于预测^[10]和基于重构^[11]的方法三类,其核心思想是对正常数据进行特征建模,与正常分布特征差异越大则表明数据为异常的可能性越大。近年来,生成对抗网络(GAN)^[12]在生成类任务中取得了显著效果,并已应用于异常检测领域,以提升数据预测或重构的有效性。然而由于核动力系统参数众多,异常种类和数据变化模式复杂,现有方法大多无法同时对核动力多元时序数据的非线性时间依赖和变量之间的空间依赖关系进行有效捕捉,进而影响异常检测的准确性。

因此,本文提出了结合门控循环单元(GRU)的混合生成对抗网络模型(NadGAN),运用GRU和对抗训练,学习正常运行状态下核动力多元时序之间的时空相关性特征,综合使用判别误差和损失误差定义异常分数,通过自适应阈值判别异常,从而提高异常检测速度和准确性。

1 方法设计

1.1 问题描述

基于多元时序数据的核动力系统异常检测指通过分析各监控参数的实时运行值与正常工况下的数据分布是否相符合,如果存在与正常样本数值差异较大、波动较大或者整体分布不同的时间点或时间序列,则视为异常。基于核动力系统的运行特点,出现异常时各参数随时间具有连续变化的特点,可归类为上下文异常和集体异常^[13]。

记长度为 N 的核动力多元(变量)时间序列为 $X = \{x_1, x_2, \dots, x_N\} \in \mathbb{R}^{m \times N}$,在 t 时刻的观测数据为

$x_t \in \mathbb{R}^m (t \in [1, N])$, m 为多元时间序列的维度,即表示每个时刻包含 m 个变量(参数)。任意时刻 t 的数据都依赖于之前的 $t-1$ 时刻,但输入模型的时序数据过长会导致建模训练困难,长度过短又会丢失时序依赖关系。因此,为了保留上下文信息,采用窗口大小为 ω 、步长为1的滑动窗口 $w_t = \{x_{t-\omega+1}, \dots, x_{t-1}, x_t\} \in \mathbb{R}^{m \times \omega}$ 对原始时间序列进行处理,转化为 $n(n \leq N)$ 个窗口子序列 $W = \{w_1, w_2, \dots, w_n\}$ 。

给定二元变量 $Y = \{0, 1\}$,核动力时序异常检测的目标是学习得到一个映射 $f: W \rightarrow Y$,能够基于异常分数输出一个未见过时间窗口数据 $w_t(t > n)$ 的异常标签 y_t 。其中, $y_t = 1$ 表示在时刻 t 的数据存在异常, $y_t = 0$ 则表示不存在异常。

1.2 总体研究方案概览

本文提出的总体方案框架如图1所示,主要分为离线分析训练和在线异常检测两个阶段。

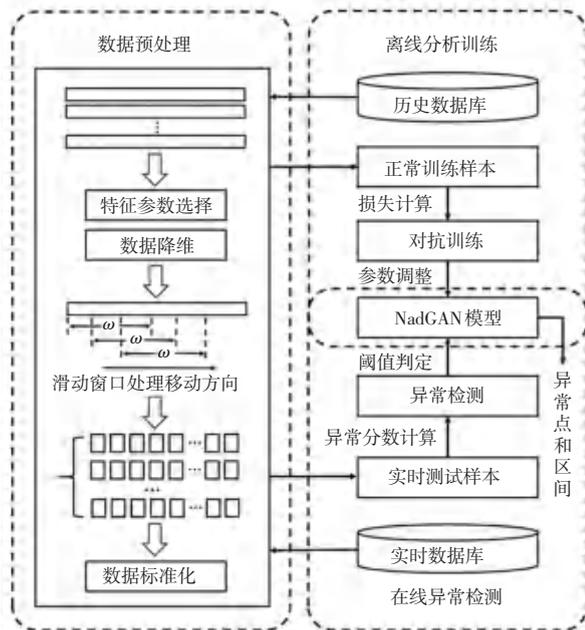


图1 研究方案总体框架图

Fig. 1 Overall framework diagram of research scheme

在离线分析训练阶段,对存储在历史数据库中的核动力系统正常运行数据经过特征参数选择、数据降维、滑动窗口以及标准化处理后输入NadGAN模型进行对抗训练,以通过损失计算调整模型参数,学习正常分布特征。模型训练完毕后,核动力系统将运行参数值存入实时数据库中,异常检测模型按照滑动窗口大小读取这部分时间序列数据,经过同样的数据预处理后,输入NadGAN模型计算异常分数,根据阈值判断是否存在异常点和异常区间,最终进行异常告警。

2 核动力时序数据异常检测

2.1 特征参数选择与处理

核动力系统中监测参数众多,为了去除噪声和不相关参数,加快模型训练和推理,需要找到关键参数作为特征输入模型。由于参数之间存在线性和非线性关系,因此首先选用最大信息系数(MIC)^[14]来计算变量 u 和 v 之间的相关性 r :

$$r = MIC(U, V) = \max_{a \times b < B} \frac{I(U; V)}{\log_2 \min(a, b)} \quad (1)$$

其中, $I(U; V)$ 表示互信息值,采用对数数据空间网格划分后统计散点分布的方式进行估算; a 和 b 分别表示在 u 和 v 方向上划分的网格数; B 表示网格数变量,一般设为数据总量的0.6次方,选择不同尺度下互信息归一化后的最大值即为最大信息系数。然后设置阈值 λ 作为特征参数的选择准则,当 $r > \lambda$ 时选择该参数作为特征参数,否则认为该参数对异常检测任务影响不大。

特征参数选择完毕后,为了进一步去除时序数据包含的冗余信息,避免过拟合,提高模型精度和泛化能力,采用主成分分析(PCA)对数据进行降维,使得降维后的数据尽可能代表原特征参数。由于不同维参数之间的量纲不同,为消除对表征和损失函数的影响,减少模型迭代次数,在输入模型前对时序数据中的每一维数据使用 Z -Score标准归一化处理,计算公式如下:

$$\tilde{x}^j = \frac{x^j - \mu(x^j)}{\sigma(x^j)} \quad (2)$$

其中, x^j 表示 x 的第 j 维变量, $\mu(x^j)$ 和 $\sigma(x^j)$ 分别表示第 j 维变量的均值和标准差。

2.2 异常检测模型结构

GAN属于生成模型中的一种,由生成器 G 和判别器 D 两个网络组成。其中,生成器用于学习输入时序数据的特征,并生成接近真实数据分布的假数据来试图欺骗判别器,判别器尝试将生成的(假)序列数据与实际的正(真)正常训练数据区分开来。 G 和 D 的网络结构可以为任意的非线性映射,这为GAN的实现提供了灵活性。传统的GAN以前馈神经网络或多层感知机作为特征提取结构,不包含时序数据处理机制,数据之间的时间依赖往往会随着时间序列长度的增加而逐渐消失。为了解决这一问题,NadGAN在GAN架构的基础上引入GRU。相比于RNN^[15],GRU^[16]能有效解决时间序列较长时的梯度消失和梯度爆炸问题,且相比于LSTM结构更简

单,在保证性能的同时加快了计算速度,并能够有效提取数据的长期时间依赖关系。NadGAN的结构如图2所示。

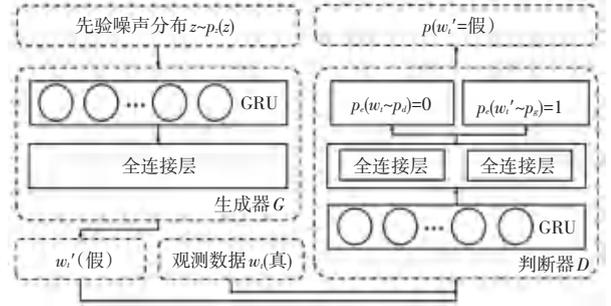


图2 NadGAN模型结构示意图

Fig. 2 Structure of the NadGAN model

2.3 离线模型训练

在NadGAN训练阶段,根据损失函数进行梯度优化,按照 D 更新1次网络参数, G 同步更新3次的方法进行训练。损失函数定义如下:

$$L_{adv} = \min_G \max_D (D, G) = \mathbb{E}_{w_i \sim p_d(w_i)} [\log D(w_i)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (3)$$

在每个循环迭代训练中,输入数据的批大小为 M ,具体训练步骤如下:

步骤1 初始化生成器 G 和判别器 D 的网络参数,执行迭代训练。

步骤2 在每一轮训练中重复执行步骤3~5,不断更新 D 的参数。

步骤3 从噪声先验分布 $p_z(z)$ 中采样得到 M 个噪声样本 $\{z_1, z_2, \dots, z_M\}$,并通过生成器 $w'_i = G(z_i)$ 生成 M 个假数据样本 $\{w'_1, w'_2, \dots, w'_M\}$ 。

步骤4 从训练数据中采集 M 个真实样本 $\{w_1, w_2, \dots, w_M\}$ 。

步骤5 联合利用 D 对于真假数据样本的输出和对应标签的误差做梯度优化,以更新 D 的网络参数。这一过程可表示为:

$$\nabla \theta_d \frac{1}{M} \sum_{i=1}^M [\log D(w_i) + \log(1 - D(G(z_i)))] \quad (4)$$

步骤6 将 G 生成的假数据作为真数据欺骗 D ,计算其输出与真实标签0的误差,用于更新 G 的网络参数。这一过程可表示为:

$$\nabla \theta_g \frac{1}{M} \sum_{i=1}^M [\log(1 - D(G(z_i)))] \quad (5)$$

2.4 在线异常检测

当模型训练完毕后,生成器 G 已学习到了正常训练数据的隐藏多元分布,如果输入 G 的隐空间向量相似,输出样本也表现出相似,则实时测试样本

w_i 与生成重构样本 $G(z_i)$ 的相似性可以解释 w_i 在多大程度上遵循 G 所反映的分布。因此可以利用 w_i 和 $G(z_i)$ 之间的重构误差 \mathcal{L}_r 识别测试数据中的异常,定义公式如下:

$$\mathcal{L}_r = \sum |w_i - G(z_i)| \quad (6)$$

由于判别器 D 能灵敏地区分假(异常)数据与真实数据,可直接将 D 的输出 \mathcal{L}_d 作为异常检测的工具,因此本文同时利用重构误差和判别器输出作为异常分数,时刻 t 数据的异常分数 s_t 计算式为:

$$s_t = \eta \mathcal{L}_r + (1 - \eta) \mathcal{L}_d \quad (7)$$

其中, η 表示平衡因子。为避免手动调参,本文采用自适应阈值的方法来判断异常。对于每个滑动窗口的阈值,定义为已输入模型的滑动窗口异常分数的平均值 \bar{S} 相差 3 个标准差,即:

$$\tau = \bar{S} + 3\sigma \quad (8)$$

将异常分数 s_t 与阈值 τ 进行比较,大于 τ 的点判定为异常,数据标注为 $y_t = 1$ 。在实际运行过程中,异常通常以连续异常段的形式出现,且操作员通常不关心时间点的异常,只要异常报警是在连续异常时间段的任何点触发即可,因此运用点调整方法^[17]来优化时序数据异常检测算法的效果。即如果输入时间窗口内的至少一点被正确检测到,则认为该时间窗口的所有数据被正确检测。

表 1 所选特征参数

Table 1 Selected feature parameters

参数名	单位	参数名	单位
1#~4#环路热段温度	°C	1#~4#堆芯入口温度	°C
1#~4#环路冷段温度	°C	1#~4#堆芯出口温度	°C
1#~4#环路流量	t/h	稳压器水位	m
1#~4#环路热段流量	t/h	稳压器压力	MPa
1#~4#环路冷段流量	t/h	喷淋流量	t/h
1#~4#环路热段压力	MPa	电加热器总功率	kW
1#~4#环路冷段压力	MPa	压力容器入口压力	MPa
1#~4#SG 水位	mm	压力容器出口压力	MPa
1#~4#SG 蒸汽流量	kg/s	压力容器入口温度	°C
1#~4#SG 蒸汽给水流量	kg/s	压力容器出口温度	°C
1#~4#SG 蒸汽出口压力	MPa	稳压器波动管温度	°C
热管段连接处波动管流量	kg/s	稳压器连接处波动管流量	kg/s

在稳态运行过程中,各参数值相对稳定,在一定范围内波动,模拟器的准确度较高。因此在固定工况参数设置下,按照 1 s 的采集频率获取 1 h 内各参数的正常运行数据,并按 4 : 1 分为训练集与验证集。为了获取包含异常的测试数据,选择 300 s 为时间尺度,在 300 s 内采用异常注入的方法触发模拟器异常事件,按照 1 s 的采集频率获取 300 s 内所

3 仿真实验评估与分析

3.1 实验数据集

为了对所提出方法的性能进行验证,本文运用四环路仿真模拟器获取核动力系统的运行时序数据。按照 2.1 节所述特征选择方法,对依据先验经验和物理模型之间的变量关系选择出的 167 个参数进行相关性计算,图 3 为参数之间的相关性热力图。最终按照 $\lambda = 0.4$ 选择出特征参数(见表 1)输入模型进行训练和测试,其中 SG 表示蒸汽发生器。

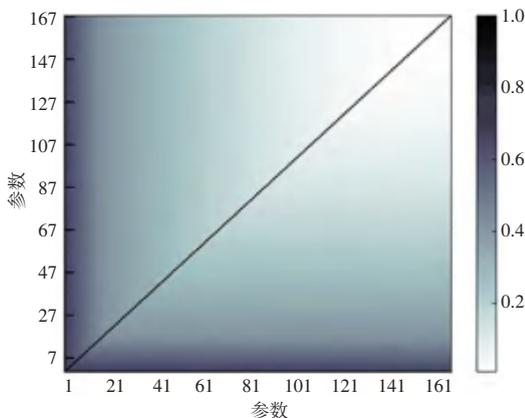


图 3 参数相关性热力图

Fig. 3 Parameter correlation heat map

选择参数的时序数据即为一个异常样本,将异常注入后的时间点标签设为 1,将正常工况运行下的时间点标签设为 0。由于本研究关注的是系统早期和微小的异常,且假设有足够的时间检测异常,因此模拟的所有异常在数据采集时间范围内不考虑紧急停堆情况。测试集统计信息见表 2,共选择 6 种核动力系统常见异常事件作为测试数据,每种异常类型

在表2所示的严重程度范围内,采用值递增的方式获取10个测试样本,并重复以上步骤获取1#~4#四个环路的测试样本数据。异常率指异常时间点占样本总运行时间的比率。

表2 测试数据集统计信息
Table 2 Test dataset statistics

异常类型	严重程度	异常率/%
1#~4#热段隔离阀前小泄露	0~5	21.4
1#~4#冷段隔离阀后小泄露	0~5	23.1
波动管破口	0~5	22.5
1#~4#SG传热管破口	0~10	19.2
1#~4#SG蒸汽出口管线破口	0~10	21.1
1#~4#SG给水管线破口	0~10	18.3

3.2 实验设置

3.2.1 性能评价指标

核动力时序异常检测对数据集进行0-1标注,是一个二分类任务,测试数据标签和异常检测模型输出的结果均包含正反例,二分类任务通常使用混淆矩阵(见表3)。为验证方法的性能,采用准确率 P 、召回率 R 和 $F1$ 分数作为度量指标。在实际应用中,由于样本不平衡,且为了减少异常漏报, R 具有最高优先级。

表3 混淆矩阵

Table 3 Confusion matrix

真实标签	预测标签	
	正例	反例
正例	真正例(TP)	假反例(FN)
反例	假正例(FP)	真反例(TN)

3.2.2 对比方法

为了评估NadGAN的异常检测效果,选择了4种具有代表性的无监督异常检测方法进行对比:局部异常因子(LOF)^[18]是一种基于密度计算的离群点检测方法;单类支持向量机(OCSVM)^[19]通过学习正常数据,寻找超平面将正常样本和异常样本分隔开;自编码器(2DCNN-AE)^[20]是一种利用深度自编码器重构误差进行异常检测的方法;EGAN^[21]是一种基于全连接网络的原始GAN异常检测模型。

3.3 实验过程与结果

3.3.1 实验过程

所有算法使用Python 3.8.8和PyTorch 1.12.0实现,基于Adam和RMSProp梯度下降优化器的小批量随机优化来更新模型参数。其中,迭代训练轮数为50,批大小 $M = 128$, D 和 G 的学习率分别设为0.0003和0.001,噪声隐向量 z 的大小为15,平衡

因子 $\eta = 0.1$ 。 D 和 G 的GRU模型分别由2层和4层隐藏单元组成。

由于在数据预处理时使用了PCA降维,为分析主成分(PC)数量对模型性能的影响,在固定阈值 $\tau = 0.64$ 和滑动窗口大小 $\omega = 50$ 的情况下,改变PC大小得到的模型性能指标如图4所示。从图4中可以看出,随着PC逐渐增大,召回率先逐渐上升,达到最高点后又逐渐下降。根据理论计算进一步分析可知,前9个主成分方差值占总方差值比率为88.81%,可代表原输入特征参数,因此选择 $PC = 9$ 作为默认最佳参数。

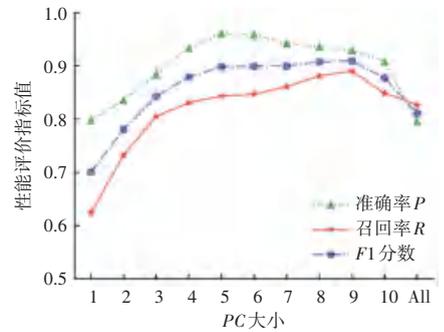


图4 不同PC大小对异常检测性能的影响

Fig. 4 Effect of PC on anomaly detection performance

滑动窗口大小 ω 对计算速度和模型性能同样会造成重要影响,参数的设定目前主要依赖于经验和实验微调。图5展示了NadGAN的各性能评价指标随 ω 的变化曲线。由图5可知,随着 ω 以10为间隔的增大,准确率和召回率整体呈现波动上升趋势,由于训练和测试时间与 ω 成正比,为了平衡时间效率和性能,设定 $\omega = 90$ 。

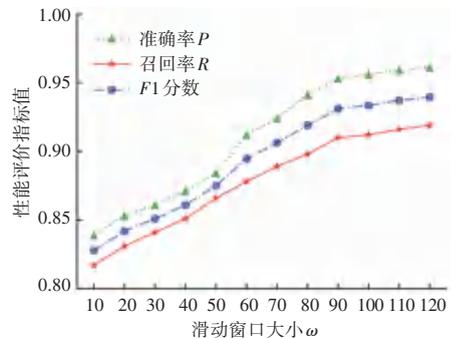


图5 滑动窗口大小 ω 对比实验结果

Fig. 5 Comparison results of ω

3.3.2 性能对比结果

图6展示了5种方法在6个测试数据集下的平均实验结果。由对比结果可以看出,NadGAN整体性能优于其他基准方法,准确率 P 、召回率 R 和 $F1$ 分数分别达到了0.953、0.912和0.932。2DCNN-

AE 利用自编码器学习正常数据特征后,利用重构误差进行异常检测,性能指标略低于 NadGAN,这是由于基于 CNN 的自编码器对于时序数据的重构能力和异常判别精准度不如结合 GRU 的生成对抗模型。EGAN 和 NadGAN 都是生成模型,相较于 EGAN, NadGAN 各项指标均有一定程度提升,证明 NadGAN 能更有效捕捉核动力多元时间序列之间的相关性特征。

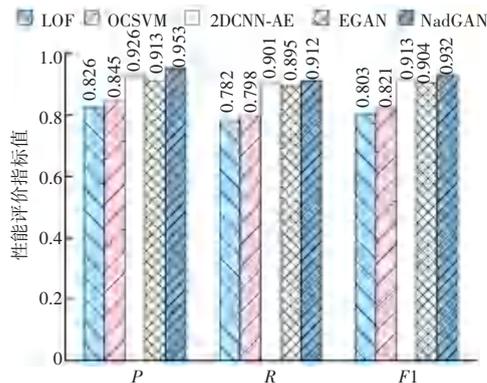


图6 不同异常检测方法对比

Fig. 6 Comparison of different anomaly detection methods

4 结束语

本研究提出了一种混合生成对抗网络模型 NadGAN,能够基于 GRU 结构,以生成器和判别器的对抗训练有效捕捉核动力系统正常运行数据的时空分布特征。并利用自适应阈值以及生成器重构误差和判别器输出对实时测试数据进行自动异常检测,以尽早发现存在异常。通过在模拟器数据集上与具有代表性的方法进行对比,证明了所提出方法在核动力系统时序异常检测上的有效性。检测出数据级别的异常后,操作员还需关注造成异常的原因。因此在后续研究中,考虑运用因果图等方法进一步对造成异常的根本原因进行分析解释。

参考文献

[1] 梁志宇,王宏志. 智能物联网时序数据分析关键技术研究综述[J]. 智能计算机与应用, 2023, 13(12): 1-8.

[2] 申煜铜,谈宇浩,夏文超. 基于联邦学习的物联网设备异常检测算法研究[J]. 智能计算机与应用, 2024, 14(8): 225-233.

[3] CLAUDIO M R S, ZIO E. A support vector machine integrated system for the classification of operation anomalies in nuclear components and systems[J]. Reliability Engineering & System Safety, 2007, 92(5): 593-600.

[4] AYODEJI A, LIU Y, XIA H. Knowledge base operator support system for nuclear power plant fault diagnosis[J]. Progress in Nuclear Energy, 2018, 105: 42-50.

[5] PENG Binsen, XIA Hong, LIU Yongkuo, et al. Research on intelligent fault diagnosis method for nuclear power plant based on correlation analysis and deep belief network[J]. Progress in Nuclear Energy, 2018, 108: 419-427.

[6] YAO Y, WANG J, LONG P, et al. Small - batch - size convolutional neural network based fault diagnosis system for nuclear energy production safety with big - data environment[J]. International Journal of Energy Research, 2020, 44(7): 5841-5855.

[7] 孙原理,宋志浩. 基于卷积长短期记忆网络和人工鲸鱼算法的核反应堆运行事件诊断方法研究[J]. 核动力工程, 2022, 43(4): 185-190.

[8] 张秀春,夏虹,刘永康,等. 基于移动窗核主成分分析的核电厂主泵故障检测[J]. 核动力工程, 2024, 45(3): 234-240.

[9] 王晓龙,张永发,刘忠,等. 基于数据驱动的核动力系统异常检测及分析方法研究[J]. 核动力工程, 2021, 42(5): 149-155.

[10] 耿柯繁,许钦,庞波,等. 基于 LSTM 的核反应堆一回路传感器故障智能检测[J]. 自动化仪表, 2023, 44(S1): 366-370.

[11] 杨继红,陈玲,王晓龙,等. 基于深度自编码器的核动力历史异常数据检测技术研究[J]. 核动力工程, 2024, 45(2): 207-213.

[12] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks; An overview[J]. IEEE Signal Processing Magazine, 2017, 35: 53-65.

[13] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection; A survey[J]. ACM Computing Surveys, 2009, 41(3): 15.

[14] KINNEY J B, ATWAL G S. Equitability, mutual information, and the maximal information coefficient[J]. Proceedings of the National Academy of Sciences, 2013, 111: 3354-3359.

[15] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. ACL, 2014: 1724-1734.

[16] ZHANG Z C, ZHOU D, ZHANG R F, et al. Medical entity relationship recognition based on bidirectional GRU and attentional mechanism[J]. Computer Engineering, 2020, 46(6): 296-302.

[17] SU Ya, ZHAO Youjian, NIU Chenhao, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network[C]// 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 2828-2837.

[18] BREUNIG M M, KRIEDEL H, NG R T, et al. LOF: Identifying density - based local outliers[C]// 2000 ACM SIGMOD International Conference on Management of Data. New York: ACM, 2000: 93-104.

[19] MA J, PERKINS S. Time-series novelty detection using one-class support vector machines[C]// Proceedings of the International Joint Conference on Neural Networks. Piscataway, NJ: IEEE, 2003: 1741-1745.

[20] KIEU T, YANG Bin, JENSEN C S. Outlier detection for multidimensional time series using deep neural networks[C]// 2018 19th IEEE International Conference on Mobile Data Management. Piscataway, NJ: IEEE, 2018: 125-134.

[21] ZENATI H, FOO C, LECOQUAT B, et al. Efficient GAN-based anomaly detection[J]. arXiv preprint arXiv, 1802.06222, 2018.