

文章编号: 1673-3193(2024)02-0205-08

# 基于对偶对抗学习的多维时间序列异常检测

李泽宇, 乔钢柱, 张苗苗

(中北大学 计算机科学与技术学院, 山西 太原 030051)

**摘要:** 时间序列中异常点的无监督检测是一个具有挑战性的问题, 要求模型能够快速准确地发现异常数据。VAE类深度神经网络模型能在数据压缩和恢复中学习数据的特征, 但由于训练过程中缺乏对抗性, 无法更好地区分正常数据和异常数据特征, 导致模型训练困难。针对该问题, 本文提出一种基于对偶对抗思想的改进多维时间序列异常检测方法。首先利用滑动窗口将数据集划分为合适的长度的序列, 使用正常序列数据训练模型。继而利用对偶结构加强两组编码器解码器之间的对抗性, 以更好地学习正常数据特征, 减少训练难度。最后, 将含有异常数据的待测数据放入训练好的模型, 根据待测序列在模型中的异常得分, 结合阈值技术进行异常判定, 并从待测数据中获得异常序列片段, 计算评价指标。实验表明, 本文方法 Dual-AE 具有模型容易训练且稳定性强的特点, 并且相对于 USAD 方法, 在水文数据集 SWaT 上  $F1$  分数提升了 0.01, 召回率提升了 0.01, 在 WADI 数据集上  $F1$  分数提升了 0.09, 召回率提升了 0.02。异常检测性能指标上, 比现有的生成式异常检测模型有明显提升。

**关键词:** 多维时间序列; 编码器-解码器; 对偶对抗学习; 异常检测

**中图分类号:** TP391

**文献标识码:** A

**doi:** 10.3969/j.issn.1673-3193.2024.02.010

**引用格式:** 李泽宇, 乔钢柱, 张苗苗. 基于对偶对抗学习的多维时间序列异常检测[J]. 中北大学学报(自然科学版), 2024, 45(2): 205-212.

LI Zeyu, QIAO Gangzhu, ZHANG Miaomiao. Anomaly detection in multidimensional time series based on dual adversarial learning[J]. Journal of North University of China(Natural Science Edition), 2024, 45(2): 205-212.

## Anomaly Detection in Multidimensional Time Series Based on Dual Adversarial Learning

LI Zeyu, QIAO Gangzhu, ZHANG Miaomiao

(School of Computer Science and Technology, North University of China, Taiyuan 030051, China)

**Abstract:** Unsupervised detection of outliers in time series was a challenging problem, and the model was required to find outliers quickly and accurately. The VAE deep neural network model could learn the characteristics of data in data compression and recovery, due to the lack of confrontation in the training process, it couldn't better distinguish the characteristics of normal data and abnormal data, which made the model training difficult. To solve this problem, this paper proposed an improved multidimensional time series anomaly detection method based on the idea of dual confrontation. Firstly, the data set was divided into sequences of appropriate length by using a sliding window, and the model was trained using normal sequence data. Then, the dual structure was used to strengthen the confrontation between the two sets of encoders and decoders,

**收稿日期:** 2023-07-07

**基金项目:** 山西省基础研究计划联合资助项目(TZLH20230818007)

**作者简介:** 李泽宇(1994-), 男, 硕士生, 主要从事时间序列异常检测方面的研究。

**通信作者:** 乔钢柱(1975-), 男, 教授, 博士, 主要从事物联网技术及应用、大数据处理技术、区块链技术的研究。E-mail: qiaogangzhu@sohu.com。

so as to better learn the characteristics of normal data and reduce the difficulty of training. Finally, the test data containing abnormal data was put into the trained model. According to the anomaly score of the sequence to be tested in the model, the anomaly judgment was made in combination with threshold technology. Abnormal sequence fragments were obtained from the data to be tested, and the evaluation index was calculated. Experiments show that the proposed method of Dual-AE has the characteristics of easy training and strong stability, comparing with USAD method, and the  $F1$  score and recall rate are increased by 0.01 and 0.01 on the hydrological dataset SWaT, and on the WADI dataset, the  $F1$  score is increased by 0.09 and the recall rate is increased by 0.02. In terms of anomaly detection performance indicators, it is significantly improved in comparing with the existing generative anomaly detection models.

**Key words:** multidimensional time series; encoder-decoder; duality adversarial learning; anomaly detection

## 0 引言

信息物理系统中, 尽早发现系统的非预期行为能够降低系统故障可能造成的社会和经济损失<sup>[1]</sup>。因此, 从信息物理系统传感器中获取的不同测量值中推断正常和异常行为具有重要意义, 有助于减少维护人力和减低检查成本, 及早发现异常并减少损失。这种对一组随时间彼此相关的测量值上的意外行为的检测, 称为多维时间序列中的异常检测<sup>[2]</sup>, 目前多元时间序列异常检测已经广泛应用于各种信息物理系统(Cyber-Physical System, CPS)中, 如IT系统的服务器异常检测和水厂攻击检测。


随着机器学习的迅速发展, 近年来许多数据驱动的方法被提出, 并取得了很好的效果。异常检测通常被认为是无监督学习, 一方面, 在数量巨大的正常数据中存在的异常样本数量非常少, 使异常数据标注非常困难, 另一方面, 异常通常不可预知且种类繁多。最常用的技术包括基于距离的方法, 如KNN<sup>[3]</sup>、聚类、K-means<sup>[4]</sup>、One-Class SVM<sup>[5]</sup>, 这些方法只能简单地捕获数据时序的关系, 对于多维时间序列中多个传感器之间的依赖关系不能很好地捕获, 数据分布的拟合效果一般, 不适用于现实的信息物理系统。

目前, 已有GANs<sup>[6]</sup>、VAE<sup>[7]</sup>、TranAD<sup>[8]</sup>、GRELEN<sup>[9]</sup>等一系列深度学习方法用于检测时态数据异常。基于自回归的多维时间序列异常检测方法通过捕获多维时间序列的时间依赖性来从规模庞大的传感器数据中检测隐藏的异常点。其中, 基于自编码器(Auto Encoder, AE)类的方法需要进行数据压缩和数据重建, 重建易受到数据中噪声的污染, 学习中缺乏对抗性, 且无法分辨


差异较小的正常数据和异常数据。基于生成式对抗神经网络的方法<sup>[10]</sup>, 主要结构包括一个生成器和一个鉴别器。生成器生成和正常数据相似分布的数据, 输送给鉴别器鉴别, 鉴别器判断数据是否来自于生成器, 两个结构相互对抗, 相互提升, 最后使用鉴别器来检测测试数据中的异常。然而, 在这种不对称的结构中, 当两个结构训练进度不一致时, 会导致双方不均衡, 使得某个结构无法很好地训练, 导致模式崩溃。由于模式崩溃和不收敛等问题, GAN训练有时较为困难。

针对上述模型存在的不足, 本文提出一种新的基于自动编码器架构<sup>[11]</sup>的方法Dual-AE, 在提高多维时间序列异常检测精度的同时减少模型的训练难度, 可以提高检测效率。本文的主要贡献如下:


1) 设计了基于AE结构的时间序列异常检测无监督方法Dual-AE, 在AE结构中增加了对抗性。受到计算机视觉(CV)领域对偶对抗思想<sup>[11]</sup>的启发, 通过改变两个AE结构对称关系强化AE模型的对抗性, 提升了模型的效果, 避免了GAN网络模型训练不平衡的问题。图1给出了原始AE模型结构和对偶对抗学习结构。



(a) AE模型结构示意图



(b) GANs模型结构示意图



(c) 对偶对抗模型结构示意图

图 1 模型结构对比

Fig. 1 Comparison of model structure

2) 在公开可用的数据集上进行了实验验证,并分析了文本方法的性能。实验表明本方法在检测时序数据的异常方面效果更好,能够较好地重建时空中数据分布,从而实现时序信息的异常检测。

## 1 相关工作

时间序列的异常检测是一项复杂的任务,已经被广泛研究。目前,人们更多地使用神经网络的方法检测异常,本文主要介绍时间序列异常检测方法和对偶学习。

### 1.1 基于神经网络的检测方法

基于深度学习的异常检测方法因其良好的性能而广受欢迎。其中,自动编码器(AE)<sup>[12]</sup>是一种流行的深度学习模型,由编码器和解码器两部分组成,编码器用于提取时间序列特征,映射到高维空间中,解码器根据高维空间特征,经过与编码器相同的变换进行重构,使重构结果与原始输入误差最小。由于训练数据全部是正常时间序列数据,得到的重建数据与异常数据相差较大,由此可检测出异常数据。但是,基于自编码器的神经网络泛化性较强,对于异常样本也能很好地重构,导致检测的误报率上升。

LSTM-AE<sup>[13]</sup>、SeqVAE-CNN<sup>[14]</sup>是两种基于LSTM的神经网络模型,这种模型使用输入序列作为训练数据,并基于每个输入时间节点预测下

一个时间戳的数据。但是,LSTM是一个递归模型,在许多具有长输入序列的情况下模型训练较为缓慢。此外,LSTM在对长时间模式镜像建模时通常效率低下,在数据有噪声的情况下尤为显著<sup>[15]</sup>。

DAGMM<sup>[16]</sup>方法使用深度自动编码高斯混合模型在特征空间中进行降维,并使用递归网络进行时间建模。自动编码器将输入数据点压缩到潜在空间中,然后由递归估计网络使用该潜在空间来预测下一个数据点。

MAD-GAN<sup>[17]</sup>利用了基于LSTM的GAN模型,并使用生成器对时间序列分布进行建模。该方法不仅用到了预测误差,还用到了异常分数中的鉴别器损失。MTAD-GAT<sup>[18]</sup>使用图注意力网络对特征和时间相关性进行建模,并利用了轻量级门控递归单元(GRU)网络,该网络有助于异常检测,且不会产生严重的开销。

USAD<sup>[19]</sup>方法使用了具有对抗性的框架,以及带有两个解码器的自动编码器。与现有方法相比,可将训练时间减少数倍。图偏差网络(GDN)<sup>[20]</sup>方法学习数据模式之间的关系图,并使用基于注意力的预测和偏差评分来输出异常分数。

### 1.2 对偶学习

对偶学习(Dual Learning)为解决无监督学习中遇到的困难提供了新的思路。对偶学习中给定一个原始任务模型,对偶任务模型可以为它提供有效反馈;同样给定一个对偶任务模型,原始任务模型也可以为其提供有效反馈,两个互为对偶的任务可以相互提供反馈,相互学习,不断促进,共同提高。

## 2 Dual-AE异常检测方法

本文提出的Dual-AE模型总体框架由数据预处理、Dual-AE模型和异常检测等3个模块组成,如图2所示。

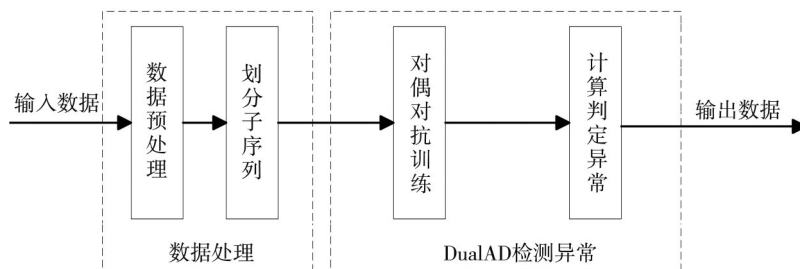


图 2 Dual-AE模型总体框架示意图

Fig. 2 The whole framework of Dual-AE model

## 2.1 自动编码器

自动编码器(AE)是一种无监督的人工神经网络,它结合了编码器E和解码器D<sup>[12]</sup>。编码器部分获取输入 $X$ 并将其映射到一组潜在变量 $Z$ ,而解码器将潜在变量 $Z$ 映射到输入空间,重构为 $R$ 。原始输入向量 $X$ 与重构 $R$ 之间的差被称为重构误差。因此,训练目标旨在使该误差最小化。其定义为

$$L_{AE} = \|X - C_{AE}(X)\|_2, \quad (1)$$

式中: $\|\cdot\|_2$ 表示 $L_2$ 范数。

$$C_{AE}(X) = C_D(Z), \quad Z = C_E(X). \quad (2)$$

基于自动编码器的异常检测使用重构误差作为异常分数。具有高分的点被认为是异常,由于训练时仅使用来自正常数据的样本,因此在推断时,AE能很好地重建正常数据,而对于AE未遇到的异常数据则无法重建数据。然而,如果异常太小,即它相对接近正常数据,但重建误差将很小,因此会导致检测不到异常,原因在于AE的原理是尽可能重建输入数据(尽可能接近正态)。为了克服该问题,AE应在进行良好的重建之前识别输入数据是否包含异常数据。

检测输入样本是否正常的方法是生成对抗网络(GANs)的特征。GAN是一种无监督的人工神经网络,基于生成模型和判别模型进行零和博弈。生成器模型 $G$ 旨在生成真实的数据,而第二个模型充当鉴别器 $D$ ,试图将真实数据与 $G$ 生成的数据区分开来。 $G$ 的训练目标是最大化 $D$ 犯错误的概率,而 $D$ 的训练目标是最小化其分类错误。

与基于AE的异常检测类似,基于GAN的异常检测使用正常数据进行训练。在训练之后,鉴别器被用作异常检测器。如果输入数据与学习数据分布不同,则鉴别器将其视为来自生成器,并将其分类为假的,即作为一个异常。然而,由于模式崩溃和不收敛等问题,生成器和鉴别器之间的不平衡,导致GAN训练有时较为困难。

无监督异常检测方法,是在两阶段对抗训练框架下的AE结构。一方面,AE架构允许通过训练能够识别输入数据何时不包含异常的模型来克服AE的固有限制,从而执行良好的重建。另一方面,AE架构允许在对抗训练期间获得稳定性,因此解决了GANs中遇到的崩溃和非收敛模式的问题。本文使用对偶对抗学习将两个AE进行连接,形成对偶对抗学习模块,加强了两个模型之间的

对抗性,从而获得检测精度更高的模型Dual-AE。

## 2.2 Dual-AE 架构设计

Dual-AE模型由两组AE模块组成,其中包含一个编码器E和两个解码器 $D_1$ 和 $D_2$ 。如图3所示,三个模型相互连接,两个解码器共享一个相同的编码器网络,组合成为 $AE_1$ 和 $AE_2$ 两个部分。

$$\begin{aligned} C_{AE_1}(W) &= C_{D_1}(C_E(W)), \\ C_{AE_2}(W) &= C_{D_2}(C_E(W)). \end{aligned} \quad (3)$$

训练分为两个阶段。首先,训练两个AE以学习重构正常输入窗口 $W$ ,其次,两个AE以对抗的方式进行训练,其中 $AE_1$ 是用来对数据添加干扰,而 $AE_2$ 的目标是从输入窗口或者重建数据中学习数据的真实分布。将输出的数据再次放到 $AE_1$ 中添加干扰。下面介绍模型细节。

1) 自动编码器训练。在第一阶段,目标是训练每个AE以再现输入。输入数据 $W$ 由编码器E映射数据到潜在空间 $Z$ ,然后由每个解码器重构。训练损失是 $L_2$ 范数。

$$\begin{aligned} L_{AE_1} &= \|W - C_{AE_1}(W)\|_2, \\ L_{AE_2} &= \|W - C_{AE_2}(W)\|_2, \end{aligned} \quad (4)$$

2) 对抗训练。目标是训练 $AE_2$ 以区分真实的数据和来自 $AE_1$ 的数据,并训练 $AE_1$ 给数据添加干扰,用来欺骗 $AE_2$ 。来自 $AE_1$ 的数据再次由E压缩到 $Z$ ,然后由 $AE_2$ 重构。来自 $AE_2$ 的数据再次由E压缩到 $Z$ ,然后由 $AE_1$ 重构。两个编码器对称,组成对偶结构,使用对偶学习加深整个模型的对抗强度,保证在训练过程中梯度不发生跃迁。 $AE_2$ 的目标是最大化这种差异。通过训练 $AE_1$ 结构生成数据,将这些数据和真实数据作为 $AE_2$ 结构的输入,目的是训练 $AE_2$ 分辨数据是真实数据还是 $AE_1$ 生成的数据。通过这种训练使得 $AE_2$ 学习到正常数据的分布特征。

训练目标为

$$\begin{aligned} &\min_{AE_1} \max_{AE_2} \|W - C_{AE_2}(C_{AE_1}(W))\|_2, \\ &\min_{AE_1} \max_{AE_2} \|C_{AE_1}(C_{AE_2}(W)) - C_{AE_2}(C_{AE_1}(W))\|_2. \end{aligned} \quad (5)$$

损失为

$$\begin{aligned} L_{AE_1} &= +\|W - C_{AE_2}(C_{AE_1}(W))\|_2, \\ L_{AE_2} &= -\|W - C_{AE_1}(C_{AE_2}(W))\|_2. \end{aligned} \quad (6)$$

自动编码器具有双重目的。 $AE_1$ 最小化 $W$ 的重构误差,并且最小化 $W$ 与 $C_{AE_2}$ 的重构输出之间

的差。与  $C_{AE_1}$  一样,  $AE_2$  使  $W$  的重构误差最小化, 但它随后使由  $C_{AE_1}$  重构的输入数据的重构误差最大化。每个  $C_{AE}$  的双重目的训练目标被表达为进化方案中的式(4)和式(6)的组合, 其中每个部分的比例随时间进化, 其中  $n$  表示训练时期。

$$L_{AE_2} = \frac{1}{n} \|W - C_{AE_1}(C_{AE_2}(W))\|_2 + \left(1 + \frac{1}{n}\right) \|W - C_{AE_2}(C_{AE_1}(W))\|_2, \\ L_{AE_1} = \frac{1}{n} \|W - C_{AE_1}(C_{AE_2}(W))\|_2 + \left(1 - \frac{1}{n}\right) \|W - C_{AE_2}(C_{AE_1}(W))\|_2. \quad (7)$$

当其输入数据为重建后的特征时, 式(5)和式(6)中的损失开始为模型拟合数据发挥作用。在检测阶段期间, 异常分数被定义为

$$A(\hat{W}) = \alpha \| \hat{W} - C_{AE_1}(C_{AE_2}(\hat{W})) \|_2 + \beta \| \hat{W} - C_{AE_2}(C_{AE_1}(\hat{W})) \|_2, \quad (8)$$

式中:  $\alpha + \beta = 1$ , 并且可以在假阳性和真阳性之间权衡。将  $\alpha < \beta$  表示为高检测灵敏度场景, 如果  $\alpha > \beta$ , 则减少真阳性和假阳性的数量; 反之, 将  $\alpha > \beta$  表示为低检测灵敏度场景, 如果  $\alpha < \beta$ , 则增加真阳性和假阳性的数量。

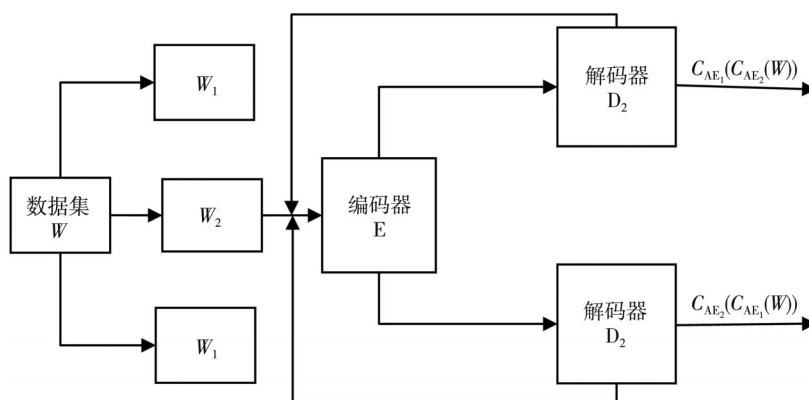


图3 Dual-AE 整体网络架构图

Fig. 3 The whole network framework of Dual-AE

### 2.3 异常检测

本文的常检测方法分为3个阶段。第一阶段是数据预处理阶段, 数据被归一化并分成长度为  $K$  的时间窗口。第二阶段使用模型训练该方法, 训练旨在捕获多维时间序列的窗口长度的正常行为, 并为每个时间窗口产生异常分数。该离线训练过程可以以规定的时间间隔自动执行。第三阶段是异常检测, 在线执行训练好的模型, 获得新时间窗口的异常分数。如果窗口的异常分数高于定义的异常阈值, 则新时间窗口内的数据被宣布为异常。

## 3 实验与分析

### 3.1 数据集

本文使用安全水处理 (SecureWater Treatment, SWaT) 数据集和水分布 (Water Distribution, WADI) 两个公开数据集进行实验。SWaT 数据集是生产过滤水的真实世界工业水处理厂的

缩小版本<sup>[21-22]</sup>, 包括 11 d 的连续操作数据, 其中包括 7 d 正常操作数据, 4 d 攻击情况下的数据; WADI 数据集<sup>[22]</sup>是 WADI 测试平台 (SWaT 测试平台的扩展) 收集的 16 d 连续运行的数据, 其中包括 14 d 正常运行状态的数据, 2 d 攻击情景下的数据。数据集的特征如表 1 所示, 其中异常比是指测试集中数据集的异常占比。

表 1 数据集的主要指标

Tab. 1 Main metrics of the dataset

数据集	特征维度	训练集数量	测试集数量	异常比/%
SWaT	51	49 500	44 991	13.87
WADI	123	78 457	17 280	6.12

### 3.2 实验设置

本文的主干网络采用了 AE, 训练时使用 Adam 优化器, 学习率为 0.001, 学习率衰减权重为每个 epoch 衰减一次, 使用全为正常的数据进行训练, 使用含有异常的数据集进行测试。实验基于 Ubuntu20 环境, 使用 Python3.8 下的 PyTorch 框架实现。硬件条件为 CPU Intel Core i7-

9750H, 内存32G, 显卡为GTX3090, 24G显存。

### 3.3 模型性能对比

为了展示Dual-AE模型的整体性能, 本文将其与5种用于检测多维时间序列异常的无监督方法进行比较, 包括自动编码器、LSTM-AE、DAGMM、USAD和MAD-GAN。由于部分用于比较对照的异常检测方法有些没有提供异常阈值, 因此本文进行多次训练, 调整超参数, 并与最高F1分数相关结果进行了对比。表2给出了所有方法在SWaT和WADI数据集上获得的性能结果。实验结果表明, Dual-AE在SWaT和WADI上的性能优于其他5种方法, 其中, USAD为论文中的评价指标, USAD(\*)为复现论文代码的结果。

表2 各方法在SWaT和WADI上的精确度、召回率和F1分数  
Tab. 2 Precision, recall and F1 scores of different methods on SWaT and WADI

数据集	方法	精确率	召回率	F1分数
SWaT	AE	0.990 3	0.629 5	0.769 7
	LSTM-VAE	0.989 7	0.637 7	0.775 6
	DAGMM	0.469 5	0.665 9	0.550 7
	USAD	0.985 1	0.661 8	0.791 7
	USAD(*)	0.955 1	0.641 8	0.771 7
	MAD-GAN	0.989 7	0.637 4	0.770 0
	Dual-AE	<b>0.962 1</b>	<b>0.662 1</b>	<b>0.790 2</b>
	WADI	AE	0.994 7	0.131 0
LSTM-VAE		0.994 7	0.128 2	0.227 1
DAGMM		0.065 1	0.913 1	0.121 6
USAD		0.994 7	0.131 8	0.232 8
USAD(*)		0.986 2	0.130 6	0.214 3
MAD-GAN		0.469 8	0.245 8	0.320 0
Dual-AE		0.948 6	<b>0.152 2</b>	<b>0.335 7</b>

由表2还可以看出DAGMM整体性能最低, 尽管其在SWaT数据集上表现较差, 但在WADI数据集上却可以通过调整参数获得较高的F1值, 这说明DAGMM独立考虑每个时间点, 将标签分配给时间点, 而不是将窗口作为一个整体考虑的方法也可以很好地检测到异常。不同的是, AE和LSTM-VAE是使用连续的观察作为输入, 对连续数据进行重建。这些方法使用效果最好的重建方法, 而不考虑输入窗口中是否存在异常, 这将导致无法检测到与正常数据差别不大的异常。USAD通过其对抗性训练弥补了基于AE的方法的这一缺点, 但是, USAD是单侧结构, 在两个结构上的对抗性不强, 异常模块添加的异常很容易

被鉴别模块识别出来, 使得一些异常点和正常点难以区分。将USAD改为对偶结果后, 强化了两个部分的对抗性, 提升了异常鉴别模块的鉴别能力, 在两个数据集上获得了更好的效果, 训练更容易, 避免了两个模块训练程度不匹配的问题。

### 3.4 模型影响因素分析

本文研究了不同参数和因素对Dual-AE性能的影响, 所有实验均在SWaT数据集上进行。

#### 3.4.1 滑动窗口大小的影响

本实验主要分析滑动窗口的大小对数据处理的影响。检测的速度由窗口的持续时间定义, 因此窗口大小影响检测出的异常行为类型和异常检测速度。表3为窗口大小 $k \in [5, 15, 30, 50]$ 对检测结果的影响。

表3 不同滑动窗口大小下的性能指标

Tab. 3 Performance indicators under different sliding window sizes

窗口大小	精确率	召回率	F1分数
5	0.94	0.61	0.76
15	0.98	0.65	0.79
30	0.97	0.58	0.62
50	0.98	0.60	0.68

由表3可以看出, 窗口大小 $k=15$ 时的检测效果最佳。当窗口较小时, 虽然检测速度较快, 但是长序列的异常数据被分割在多个窗口中, 无法被模型捕捉到, 从而无法检测到这些异常序列。当窗口增大到10以后, 模型就能有效地捕获长序列的特征信息。捕获的这些特征可以让模型获取时间序列前后的特性, 从中很好地判断正常和异常序列。当窗口大小超过15后, 检测速度比较慢, 同时部分较长的异常序列被判定为正常序列, 可能是由于训练的数据集中正常序列和这几段异常序列的分布差别较小、序列长、数据量比较大的时候, 模型无法很好地区分这些长序列, 造成了更多的假阴性判断。

#### 3.4.2 迭代次数和损失值的影响

本实验主要分析训练中迭代次数与损失值的变化情况。分别测试epoch=[20, 100, 200, 400]情况下, 模型训练的收敛速度。实验结果表明, 当迭代超过100次后基本趋于收敛。由于使用了两个对偶对抗的结构, 所以在训练过程中模型的损失分为两部分, 其中损失大部分情况下平缓提升和下降, 直到收敛。然而, 在参数矩阵初始化不同的情况下, 有时会出现对抗网络损失跳跃的

现象,部分情况损失会向反向跃迁。当给定参数随机种子后基本能够保证损失不会反方向下降。

### 3.4.3 参数 $\alpha$ 和 $\beta$ 的影响

本文对式(8)中两个参数 $\alpha$ 和 $\beta$ 取不同值时对模型评价指标的影响进行了研究。试验结果表明,增加 $\alpha$ 和减少 $\beta$ ,可以减少被模型预测为正类的负样本的数量,同时限制被模型预测为正类的正样本数量的下降。

## 4 结论

本文提出了基于自动编码器的多维时间序列无监督异常检测方法(Dual-AE),在对偶对抗学习的启发下设置了对偶结构进行对抗性训练,这种自动编码器架构能够在对抗训练期间表现出极大的稳定性,且不需要提前标注。在SWaT和WADI两个数据集上的实验结果表明,Dual-AE模型具有收敛速度快、效果稳定、检测准确率高、误检率低的特点。该方法比现在流行的GANs模型训练难度小,迭代次数低。与基于自动编码器的方法相比加深了对抗结构之间的对抗性,能够更好地训练鉴别器区分正常数据与异常数据。另外,该模型在多维时间序列异常检测方面有良好的效果,在未来仍然具有研究价值。

### 参考文献:

- [ 1 ] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks [DB/OL]. (2017-01-17)[2023-07-07]. <http://arxiv.org/abs/1701.04862v1>.
- [ 2 ] PANG G, SHEN C, CAO L, et al. Deep learning for anomaly detection: A review [J]. ACM computing surveys (CSUR), 2021, 54(2): 1-38.
- [ 3 ] CHAOVALITWONGSE W A, FAN Y J, Sachdeo R C. On the time series  $k$ -nearest neighbor classification of abnormal brain activity[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2007, 37(6): 1005-1016.
- [ 4 ] KISS I, GENGE B, HALLER P, et al. Data clustering-based anomaly detection in industrial control systems [C]//2014 IEEE 10th International Conference on Intelligent Computer Communication and Processing (ICCP). IEEE, 2014: 275-281.
- [ 5 ] MA J, PERKINS S. Time-series novelty detection using one-class support vector machines[C]//Proceedings of the International Joint Conference on Neural Networks, 2003. IEEE, 2003, 3: 1741-1745.
- [ 6 ] 霍纬纲, 梁锐, 李永华. 基于随机Transformer的多维时间序列异常检测模型[J]. 通信学报, 2023, 44(2): 94-103.  
HUO Weigang, LIANG Rui, LI Yonghua. Multidimensional time series anomaly detection model based on random transformer [J]. Journal of Communication, 2023, 44(2): 94-103. (in Chinese)
- [ 7 ] 段雪源, 付钰, 王坤. 基于VAE-WGAN的多维时间序列异常检测方法[J]. 通信学报, 2022, 43(3): 1-13.  
DUAN Xueyuan, FU Yu, WANG Kun. Anomaly detection method for multidimensional time series based on VAE-WGAN [J]. Journal of Communication, 2022, 43(3): 1-13.
- [ 8 ] TULI S, CASALE G, JENNINGS N R. TranAD: Deep transformer networks for anomaly detection in multivariate time series data [DB/OL]. (2022-01-18) [2023-07-07]. <https://arxiv.org/abs/2201.07284>.
- [ 9 ] ZHANG W, ZHANG C, TSUNG F. Grelen: Multivariate time series anomaly detection from the perspective of graph relational learning [C]//Thirty-First International Joint Conference on Artificial Intelligence, IJCAI-22, 2022: 2390-2397.
- [ 10 ] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview [J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [ 11 ] YI Z, ZHANG H, TAN P, et al. Dualgan: Unsupervised dual learning for image-to-image translation [C]//IEEE International Conference on Computer Vision, 2017: 2849-2857.
- [ 12 ] KIEU T, YANG B, JENSEN C S. Outlier detection for multidimensional time series using deep neural networks [C]//19th IEEE international conference on mobile data management (MDM). IEEE, 2018: 125-134.
- [ 13 ] NIU Z, YU K, WU X. LSTM-based VAE-GAN for time-series anomaly detection [J]. Sensors, 2020, 20(13): 3738.
- [ 14 ] ZHAO H, WANG Y, DUAN J, et al. Multivariate time-series anomaly detection via graph attention network [C]//2020 IEEE International Conference on Data Mining (ICDM). IEEE, 2020: 841-850.
- [ 15 ] PARK D, HOSHI Y, KEMP C C. A multimodal anomaly detector for robot-assisted feeding using an lstm-based variational autoencoder [J]. IEEE Robotics and Automation Letters, 2018, 3(3): 1544-1551.

- [16] ZONG B, SONG Q, MIN M R, et al. Deep autoencoding gaussian mixture model for unsupervised anomaly detection [C]//International Conference On Learning Representations, 2018: 1-19.
- [17] LI D, CHEN D, JIN B, et al. MAD-GAN: Multivariate anomaly detection for time series data with generative adversarial networks[C]//International Conference on Artificial Neural Networks. Cham: Springer International Publishing, 2019: 703-716.
- [18] ZHAO H, WANG Y, DUAN J, et al. Multivariate time-series anomaly detection via graph attention network [C]//2020 IEEE International Conference on Data Mining (ICDM). IEEE, 2020: 841-850.
- [19] AUDIBERT J, MICHIARDI P, GUYARD F, et al. Usad: Unsupervised anomaly detection on multivariate time series [C]//26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020: 3395-3404.
- [20] DENG A L, HOOI B. Graph neural network-based anomaly detection in multivariate time series [C]//AAAI Conference on Artificial Intelligence, 2021: 4027-4035.
- [21] GOH J, ADEPU S, JUNEJO K N, et al. A dataset to support research in the design of secure water treatment systems[C]//Critical Information Infrastructures Security: 11th International Conference, CRITIS 2016, Paris, France, Springer International Publishing, 2017: 88-99.
- [22] MATHUR A P, TIPPENHAUER N O. SWaT: A water treatment testbed for research and training on ICS security [C]//2016 International Workshop on Cyber-Physical Systems for Smart Water Networks (CySWater). IEEE, 2016: 31-36.