

DU Xiaolong, BAI Meng. Anomaly Detection Method for Satellite Telemetry Parameters Based on Time-series Imputation Generative Adversarial Networks (in Chinese). *Chinese Journal of Space Science*, 2025, 45(4): 1087–1097. CSTR:32142.14.cjss.2024-0099. DOI:10.11728/cjss2025.04.2024-0099

基于时序插补生成式对抗网络的卫星 遥测参数异常检测方法*

杜晓龙 白 萌

(中国科学院国家空间科学中心 北京 100190)

(中国科学院大学 北京 100049)

摘 要 为确保卫星的安全稳定运行, 及时进行遥测参数的数据挖掘、态势分析及异常响应至关重要。鉴于现有方法在处理卫星遥测参数异常时存在的局限性, 提出一种基于时序插补和生成式对抗网络的异常检测方法。该方法通过一维卷积神经网络提取时序特征, 并利用生成式对抗网络对遥测参数的分布进行建模, 创新性地采用基于插补的检测方式, 有效提高了异常检测的准确性和对复杂异常情况的适应能力。基于真实卫星数据和公开数据集的测试结果表明, 与多种已有方法相比, 本文方法在多数数据集上获得了最高的 F_1 分数, 并在不同的异常浓度下显示出良好的稳定性。这一研究成果为卫星任务的地面运控进行卫星态势分析和异常处置提供了有力的决策支持。

关键词 遥测数据, 时序异常检测, 一维卷积神经网络, 生成式对抗网络, 插补生成

中图分类号 V474

Anomaly Detection Method for Satellite Telemetry Parameters Based on Time-series Imputation Generative Adversarial Networks

DU Xiaolong BAI Meng

(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

(University of Chinese Academy of Sciences, Beijing 100049)

Abstract To ensure the safe and stable operation of satellites, it is of paramount importance to promptly conduct data mining, situation analysis, and abnormal response for telemetry parameters. Given the limitations of existing methods in effectively addressing satellite telemetry parameter anomalies, this paper introduces an innovative anomaly detection method that leverages temporal interpolation and Generative Adversarial Networks (GANs). The proposed method employs a one-dimensional Convolutional Neural Network (CNN) to extract temporal features, and utilizes a Generative Adversarial Network (GAN) to model the distribution of telemetry parameters. Innovatively, the method adopts an interpolation-based detection approach, which effectively improves the accuracy and adaptability of anomaly detection for complex situations. Test results based on real satellite data and public datasets show that, compared to multiple existing methods, the proposed method achieves the highest F_1 score on most datasets, and demonstrates good stability under different anomaly concentrations. This research result provides a strong decision support for satellite task ground operations to conduct satellite situation analysis and abnormal disposal.

* 中国科学院空间科学战略性先导科技专项项目 (XDA15040100) 和中国科学院青年创新促进会项目 (E1213A05) 共同资助

2024-08-03 收到原稿, 2024-12-12 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

tional Neural Network (1DCNN) to extract temporal features from the telemetry data. These features are then used to model the distribution of telemetry parameters through a generative adversarial network, which consists of a generator and a discriminator that are trained simultaneously to learn the distribution of normal data. The method innovatively incorporates a detection approach based on interpolation, which significantly enhances the accuracy of anomaly detection and the capability to handle complex and subtle anomalies that may not be easily identified by traditional methods. The effectiveness of the proposed method is validated through comprehensive testing on real satellite data as well as established public datasets. Results demonstrate that, when compared with various existing anomaly detection methods, the proposed approach achieves the highest F_1 scores on the majority of the datasets tested. This indicates a superior balance between precision and recall, which is crucial for reliable anomaly detection. Furthermore, the method exhibits good stability under different anomaly densities, suggesting its robustness in varying operational conditions. This research outcome not only enhances the understanding of satellite telemetry anomalies but also provides strong decision support for ground operation in satellite mission analysis and anomaly handling, thereby contributing to the overall safety and efficiency of satellite operations.

Key words Telemetry data, Temporal anomaly detection, One-dimensional convolutional neural networks, Generative adversarial networks, Interpolation generation

0 引言

随着空间探索的不断深入, 空间科学已成为科学发展和技术进步的重要推动力^[1]. 卫星等航天器作为发展空间科学的重要载体, 扮演着至关重要的角色^[2]. 开展空间科学研究所需观测和实验大多需要在卫星平台进行. 因此, 卫星的正常稳定运行对于确保空间科学任务的科学产出至关重要. 然而, 空间环境复杂多变, 存在空间粒子辐射^[3]等诸多影响卫星运行的因素. 这些恶劣的环境因素以及卫星自身部件老化等原因, 可能导致卫星在轨运行过程中发生各种异常情况, 带来许多安全风险并影响科学产出. 研究表明, 近年来已有多起卫星故障发生, 造成了严重的影响^[4]. 因此, 对卫星的在轨运行状态进行实时监测, 及时发现可能出现的问题并采取有效应对措施, 对于保障卫星在轨运行的可靠性和稳定性具有重要意义.

要对卫星状态进行全方位、全天时监测, 离不开遥测参数的支持. 遥测参数是卫星系统将传感器记录的电压、温度等信息以规定的形式组成数据帧传送给地面系统的数据^[5]. 通过对遥测参数进行异常检测分析, 及时处理异常情况, 是保障卫星平稳可靠运行的有效手段^[6]. 由于异常数据相对较少且极度缺乏标签, 异常检测常被视为一种无监督学习的不平衡二分类问题. 传统的检测方法包括基于统计分布的方法 (如

Z-score^[7])、基于距离的聚类方法 (如 K-NN^[8]) 以及基于密度的聚类方法 (如 DBSCAN^[9]). 随着计算机技术的发展, 深度学习方法也被越来越多地应用于异常检测任务, 以期解决更复杂的异常问题, 包括基于预测的算法 (如 AdcGAN^[10], FEDformer^[11]) 以及基于重构的算法 (如 TAnoGAN^[12], LSTM-VAE^[13]).

尽管已经有了如此多的检测算法, 卫星遥测参数的异常检测任务仍是一个值得深入研究的复杂问题. 首先, 由于卫星运动的复杂周期性, 对遥测参数进行建模和分析存在一定难度, 现有方法的有效性有待提升. 其次, 现有方法较少考虑异常数据集中出现的现象, 这导致检测方法的鲁棒性较差, 可能仅在特定数据集上表现良好.

针对上述问题, 本研究提出了一种基于时序插补生成式对抗网络的卫星遥测参数异常检测方法. 该方法主要针对卫星遥测参数中单参数异常, 利用生成式对抗网络对正常遥测参数进行建模, 解决了传统方法无法准确建模复杂时序数据的问题, 并采用时序插补策略来有效检测异常情况, 避免了传统基于重构或预测的方法在较为复杂异常情况下表现不佳的问题.

1 时序异常检测问题

针对卫星遥测参数的异常检测研究, 主要可以分为两个方向: 一是专注于单一参数的时序特征, 重点

分析参数在时间序列中的上下文特征, 以识别异常; 二是关注多参数间的相关性, 主要探讨多个参数间的相互关系是否存在异常. 在本研究中, 计划采用时序生成建模的方法, 集中研究单参数在时间序列上的异常情况, 更深入地挖掘其异常特征.

1.1 卫星遥测参数时序异常分类

遥测参数, 根据其数据采集方式, 主要分为连续量和离散量两大类^[6]. 连续量是卫星搭载的传感器以秒为单位进行采样而获取的信息, 涵盖电压、温度等关键参数; 离散量则涉及卫星内部各种开关的状态以及计数信息. 在单参数异常检测的背景下, 连续量因其反映的细微变化而显得尤为关键. 本文后续讨论的遥测参数是指这些连续采集的参数.

遥测参数作为连续时间序列数据, 直接映射了卫星的实时工作状态, 与卫星的运行状况紧密相关. 为确保卫星的稳定运行, 许多遥测参数必须维持在预定的正常范围内. 然而, 由于卫星运动及地球自转、公转等复杂因素的叠加影响, 遥测参数的变化呈现出高度的周期性, 这无疑增加了异常检测的难度.

尽管卫星的遥测参数具有多维度特性, 但是全面分析所有参数不仅耗时耗力, 而且效率不高. 研究表明, 卫星同一部件的多个参数变化之间存在高度的相似性. 因此, 选择一个关键参数即可有效表征该部件的运行状态. 本研究专注于单参数在时间维度上的异常变化, 参数选择依照的是卫星系统专家制定的重点参数监控表.

单参数数据的异常状态检测可分为两大类: 基于点的异常 (Point-based Anomalies) 和基于序列的异常 (Sequence-based Anomalies)^[14,15]. 点异常指的是时间序列中个别数据点显著偏离正常值, 进一步细分为单点异常 (Point Anomalies) 和上下文异常 (Contextual Anomalies). 单点异常是指孤立的数据点与其他数据点相比存在显著差异, 如图 1(a) 所示; 上下文异常则指在特定上下文或条件下某个数据点显得异常, 如图 1(b) 所示. 序列异常涉及时间序列中连续的多个数据点共同表现出的异常模式, 如图 1(c) 所示, 称为集体异常 (Collective Anomalies), 表现为一系列数据点的异常波动或趋势, 通常与时间序列的整体行为或模式相违背.

1.2 单参数时序异常检测问题定义

异常检测问题本质上是一个二分类问题, 其目标

是将数据分为正常和异常两大类. 在单参数时序异常检测领域, 此任务特指评估给定时间序列是否遵循正常的数据分布模式, 并且识别是否包含上述 3 种异常类型.

通常采用滑动窗口技术处理时序数据, 进行异常检测. 如图 2 所示, 对于长度为 l 的时间序列数据 $X = \{x_1, x_2, x_3, \dots, x_l\}$, 定义一个时间窗口, 其大小为 ω (即窗口内包含连续数据点的数量), 步长为 s (即每次窗口滑动时移动的数据点数). 这种划分策略可对每个子序列独立进行异常检测, 识别异常子序列.

此外, 异常样本在数据集中通常较为稀缺, 导致正常与异常类别之间存在显著的类别不平衡, 这可能会对异常检测的效果产生不利影响. 为解决这一问题, 这里采用区间异常检测的标准, 代替传统的点异常检测, 即如果一个子序列中包含至少一个异常点, 则该子序列会被标记为异常. 从实际应用角度来看, 异常点周围的连续数据点同样重要, 因为其有助于分析异常的成因, 帮助评估异常对系统的影响.

2 时序插补的异常检测算法

2.1 算法基本框架

针对卫星遥测参数的时序异常检测任务, 本文提出一种基于时序插补生成式对抗网络的卫星遥测参数异常检测方法 (TiGAN). 其核心思路是生成对抗和插补检测, 利用生成对抗网络 (GAN) 来建模遥测




图 1 三种时序数据异常类型

Fig. 1 Three time-series data exception types




图 2 滑动窗口处理时序数据

Fig. 2 Sliding window processing timing data

参数, 利用时序插补特征解决复杂异常状况下的数据生成及检测问题.

TiGAN 采用一种无监督学习策略, 其核心优势在于无须依赖预先标注的异常标签即可完成模型的训练和异常识别. 这一特性对于卫星遥测参数这类难以获得准确标注的异常数据尤为重要. 无监督学习算法直接从数据本身的结构和模式中提取特征, 并识别出不符合正常数据分布的异常点.

图 3 给出 TiGAN 异常检测算法的工作原理, 从图 3 中可以看出, 研究方法主要分为两个阶段. 首先是时序数据的特征学习阶段, 该阶段采用一维卷积神经网络 (1DCNN) 与生成式对抗网络 (GAN) 相结合的结构. 1DCNN 专注于捕捉时间序列数据中的局部特征, 而 GAN 则通过对抗学习机制生成与原始数据分布一致的完整数据序列. 这种结合不仅增强了模型对时间序列局部特征的捕捉能力, 还通过生成器与判别器之间的相互作用, 提升了特征学习过程的深度和广度.

其次是异常检测阶段, 该阶段基于特征学习阶段获得的生成器模型, 通过评估插补数据与原始数据之间的差异进行异常检测. 具体而言, 如果插补后的数据与原始数据之间的差异超出了预设的阈值, 则相应的数据点或序列将被判定为异常. 这种方法有效利用了无监督学习的优势, 通过模型自身的学习过程来界定正常与异常的边界, 从而在无需人工标注的情况下实现异常的自动识别.

2.2 基于 1D-CNN-GAN 的特征学习

卷积神经网络 (CNN) 是深度学习中主要用于图像分析的一类重要模型, 其通过卷积层与池化层的结




图 3 TiGAN 异常检测算法框架

Fig. 3 Framework of TiGAN anomaly detection algorithm

合, 有效提取图像特征并进行分类. 本研究所使用的 1DCNN 是 CNN 的一种特殊形式. 图 4 给出了一维卷积的原理过程, 其卷积核仅在单一维度上进行滑动, 即在时间序列或一维空间数据上. 这种设计使得 1DCNN 非常适合用于处理序列数据, 例如音频信号、文本、时间序列等.

卷积核是 1DCNN 提取时序特征的重要组成部分, 其通过与滑动时间窗口内的数据进行卷积操作, 实现时序数据的特征提取. 对于单参数时间序列 x 以及卷积核 k , 其卷积操作为

$$S_t = (x \otimes k)[t] = \sum_{i=1}^{n_k} x_{t-i+1} k_i. \quad (1)$$

其中, $[t]$ 为时间序列 x 的长度, $\otimes$ 为卷积算子, n_k 为卷积核 k 的大小, S_t 为对应的一维卷积操作的输出. 卷积操作后, S_t 的长度为 $n_x - n_k + 1$, 其中 n_x 为序列 x 的时间步长.

1DCNN 的核心在于其卷积核的设计, 这些卷积核能够捕捉时间序列数据中的局部特征. 例如, 一个具有权重为 $(-1, 0, 1)$ 的卷积核就能够检测时间序列中局部的平滑性. 图 5 给出一个平滑卷积检测示例, 当输入序列在某个子区间内变化较为平缓时, 该卷积核 k 与序列的卷积操作的输出将趋近于零. 相反, 如果子序列中存在显著的数值波动, 则卷积结果将显著偏离零值. 对于单参数的时序数据而言, 1DCNN 在训练过程中通过反向传播不断优化卷积核的权重, 实现对一维时间序列数据的特征提取和表示.

GAN 是由 Goodfellow 等^[16] 在 2014 年提出的一种基于深度学习的生成式模型. 生成式模型是通过学习原始数据的潜在规律, 生成与原始数据相同分布的新数据. GAN 主要由生成器 G (Generator) 和判别器 D (Discriminator) 两部分组成. 生成器的目标是生成尽可能真实的数据, 而判别器的目标是正确区分真




图 4 一维卷积过程

Fig. 4 Process of one-dimensional convolution

实数据与生成数据. 在训练过程中, 生成器与判别器相互对抗, 不断调整参数, 使得生成器生成的数据越来越接近真实数据, 判别器也越来越难以区分. 最终的训练目标是使生成器 G 非常强大, 能够生成与真实数据分布相似的数据.

在时序异常检测任务中, 生成器 G 需要从原始序列数据 X 中学习数据分布 p_g , 用于从待插补数据序列 x_i 中生成新数据 x_g . 判别器 D 的目标则是最大限度区分真实数据和插补生成的数据. 判别器输出一个标量 $D(x; \theta_d)$, 代表 x 是真实数据的概率. 当 $x \approx p_{\text{data}}(x)$ 时, 判别器期望输出是 1; 反之, 当 $x \approx p_g(x)$ 时, 期望输出为 0. 在 GAN 中, 生成器 G 和判别器 D 是同时进行训练的, 训练目标是调整生成器 G 的参数, 实现最小化 $1 - D(G(x_i))$, 同时调整判别器 D 的参数以最大化 $D(x)$, 损失函数为

$$L = \min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\ln D(x)] + E_{x \sim p_g(x)} [\ln(1 - D(G(x_i)))]. \quad (2)$$

对于时序异常检测任务, 由于异常数据的占比特别小, 其对整体数据分布特征的影响也微乎其微, 因此可以通过未标注的数据来进行学习. 通过 GAN 配合 1DCNN, 可以学到时序遥测参数的分布特征, 由此进行异常检测.

2.3 基于插补的异常检测

基于深度学习的时序异常检测方法主要是从学习数据特征分布开始的, 学到这些分布之后的检测方法主要分为以下两种.

第一种方法是预测型异常检测, 如图 6 所示, 其利用时间窗口内早期数据点来预测后续数据点. 具体而言, 首先对时间窗口内的部分数据进行建模, 然后基于该模型预测窗口内的剩余数据或最后一个数据点. 异常存在与否通过评估预测误差来确定. 如果预测误差超过了某个预设的阈值, 则可认为存在异常.

第二种方法是重构型异常检测, 如图 7 所示, 其




图 5 平滑卷积检测示例

Fig. 5 Smooth convolution detection example

通过将整个时间窗口的数据映射到一个低维隐空间, 再从隐空间解码回原始空间, 以此来重构原始数据. 异常的检测是基于重构误差来进行的. 如果原始数据与重构数据之间的误差超过某个阈值, 则可认为数据点是异常的.

上述两种基于特征分布的异常检测方法虽然取得了一定成果, 在一些异常检测任务中表现优异, 但是在应用于卫星遥测参数的异常检测任务时, 其性能并不总是令人满意. 通过深入分析卫星遥测参数数据集以及现有的异常检测数据, 发现异常值倾向于在特定的时间区间内集中出现. 现有的预测和重构方法并没有充分考虑这种集中出现的异常模式, 这导致检测结果的稳定性和准确性受到影响.

基于深度学习的方法在异常检测中通常从原始数据出发, 假定异常的影响较小, 学习数据的特征分布. 但是, 当异常数据较多或集中出现时, 会使得数据分布发生偏差, 影响检测效果. 为解决现有方法在卫星遥测参数异常检测中的局限性, 这里提出一种新的插补策略 (见图 8). 该策略的核心是在异常检测流程中引入异常点的预识别与插补步骤, 提高模型对异常的识别能力, 并减少密集异常点对模型性能的影响. 从图 8 中可以看出, 将原始序列的一些数据变换为 -1, 再通过插补生成新的序列数据, 根据插补点的偏




图 6 预测型方法的检测逻辑

Fig. 6 Detection logic of predictive methods




图 7 重构型方法的检测逻辑

Fig. 7 Detection logic of reconstructed methods

差来判断是否存在异常。

与基于预测的方法相比,本研究提出的插补策略选择的点不是连续的,有效避免了连续异常数据对检测结果的干扰。同时,与基于重构的方法相比,该策略保留了部分原始数据作为已知点,提高了插补过程的稳定性。基于插补后的数据与原始数据之间的误差进行异常判断,可以更准确地捕捉到数据中的异常模式,提高异常检测的准确性。

基于运算时间及插补效果,采用基于数据偏离程度的插补策略,即尽可能选取离区间平均值较远的数据点作为未知数据。对于长度为 w 的序列数据 X ,计算每个数据点与区间平均值的差值 $|x_i - \bar{x}|$,选取其中最大的 n 个用于插补检测。

2.4 算法流程

对时间序列数据 X 进行异常检测,首先需对其进行归一化处理,使得所有的数据位于 $[0, 1]$ 区间内,方便后续检测。然后采用滑动窗口策略,将 X 分为若干个长度为 w 的时间窗口 X_w 。

检测算法整体包括特征学习和异常检测两部分。特征学习部分整体由生成器 G 和判别器 D 组成,其都是依托1DCNN进行实现的。判别器 D 包含4个一维卷积层和一个全连接输出层,接受一个时间序列 X ,通过卷积操作分析其数据分布,通过最后的全连接层以及sigmoid激活函数输出一个标量,0表示判别为生成数据,1表示判别为原始数据。生成器 G 包含3个不同卷积核大小的一维卷积层以及一个卷积输出层,接受一个归一化后的时间序列 X_w ,根据数据点偏离序列的程度将 n 个数据点修改为-1,表示掩码。修改后数据经过一系列卷积操作后再与掩码进行异或操作,即只修改值为-1位置的数据,其余数据保持为原始输入,这样就得到与输入序列长度相同的生成数据 X_g 。特征学习部分的训练流程如下。

步骤1 初始化生成器 G 和判别器 D 。

步骤2 进行 G 和 D 迭代训练,在迭代次数 n 内,重复执行步骤3~8。




图8 插补方法的检测逻辑

Fig. 8 Detection logic of interpolation methods

步骤3 重复执行 k 次步骤4~6,不断更新 D 的参数。

步骤4 将原始数据窗口 x_o 输入到 D 中,得到损失 d_{real} 。

步骤5 将 x_o 输入 G 中,输出的结果 x_g 输入 D 中,得到损失 d_{fake} 。

步骤6 使用Adam优化器更新 D 的参数 θ_d 。

步骤7 进行生成器的训练,将 x_o 输入 G 中,得到损失 g_{loss} 。

步骤8 使用Adam优化器更新 G 的参数 θ_g 。

步骤9 完成迭代训练后,返回 G 和 D 。

迭代训练完成收敛的生成器 G 就可以用来实现检测操作。将 X_w 按照顺序逐一输入 G 中得到插补输出 X_g ,若 X_g 中存在任意一个点 x_i 与原始数据中相同位置的数据 x_o 的差值大于阈值 s ,即认为该区间存在异常。

3 实验验证

3.1 实验环境及数据集

本研究所有实验的环境及配置见表1。

本研究构建的单参数数据集来源于中国某空间科学卫星在2023年产生的延时遥测数据。这些数据涵盖电源分系统(DY)、姿态控制分系统(ZK)以及热控分系统(RK)等关键遥测参数,是判断卫星正常运行的重要指标。同时,本研究还选取业界公认的标准单参数时序异常数据集——Numenta Anomaly Benchmark (NAB)^[17]中的亚马逊云服务器设备异常数据集(AWS)作为对照。该数据集广泛用于评估异常检测算法的性能,其包含在实际工作条件下采集的CPU、磁盘、网卡等多种设备的数据,与本文研究关注的卫星遥测参数具有较高的相似性。

对于NAB公开数据集,根据其提供的异常时间窗口来识别异常区间。该数据集共包含17段异常数据,平均每段数据长度约为3985个时间点。根据表2中显示的离散程度,该公开数据集中异常数据的比例为9.32%。对于自建的延时遥测数据集,采用了基于专家经验的标注方法,将专家认为异常的数据段标记为异常。从表2中可以看出,卫星在大多数时间内运行正常,异常数据的比例相对较低。具体来说,电源、热控、姿控分系统分别包含5段、7段和4段异常

数据,详细数据分布情况见表 2.

此外,在 3.3 节中,为验证不同实验设置下算法的性能以及在不同的异常浓度下各种算法的检测效果,采用对遥测数据进行加工注入异常的方法.通过编程设计了单点异常、上下文异常、集体异常等多种异常类型,并根据不同的设置或浓度注入不同比例的异常数据.

所有数据均经过归一化处理,缩放到 $[0, 1]$ 区间内,以便确定检测阈值.表 2 中详细对比了所选公开数据集和自建数据集的统计特征.对于每个数据集,计算了数据的平均长度,并统计了超过平均值 2 个标准差 (2σ) 至 3 个标准差 (3σ) 的数据点占比,以此表明数据的离散程度.同时还分析了异常数据在整个数据集中所占的比例.值得注意的是,本研究提出的方法基于无监督学习,其显著优势在于无须依赖标签数据即可完成模型的训练和异常检测.数据集中的异常标签仅用于评估算法的性能,而不用于模型训练过程.此外,由于采用无监督学习方法,避免了将数据集划分为训练集和验证集的步骤,这不仅简化了数据处理流程,还减少了对大量标注数据的需求.

3.2 实验结果及对比

为验证 TiGAN 的检测效果,选取一段包含 3 个已知异常区间的时间序列样本进行分析.图 9 给出检

测结果,其中图 9(a) 显示了原始数据及其已知异常区间的标记;图 9(b) 对比了插补生成的数据与原始数据,可以看出插补数据整体上遵循了原始数据的分布规律,但在某些显著异常点附近,插补数据与原始数据存在明显差异,这与算法设计初衷相符;图 9(c) 显示了最终的异常检测结果,所有已知异常区间均被成功识别.此外,算法还检测出一些潜在的异常区间,这些区间的数值表现与周围数据有显著差异,值得进一步分析.总体来看,在没有异常标签的情况下,算法通过生成对抗学习机制成功建模了原始时间序列,生成的数据既符合原始数据的分布特征,又在潜在异常点处表现出一定差异性,适合用于对比检测.

图 10 给出了本文提出的基于插补的方法与传统基于重构或预测的方法在生成数据方面的对比.可以看出,基于预测的方法在单点异常附近表现较好,基本不受影响,但在集体异常区域,预测生成的数据会受到明显干扰;基于重构的方法则相反,受集体异常影响较小,但是单点异常容易引发大范围的生成数据波动,可能导致误判.相比之下,基于插补的方法在不同的异常区域的表现更加稳定,不仅在单点异常下表现出色,而且在集体异常区域受到的影响也较小,能较好地应对复杂异常情况.

为量化本文提出的 TiGAN 算法的效果,选取了基于统计数值的 Z-score^[7] 算法,基于距离聚类的 LOF^[18] 算法,基于密度聚类的 DBSCAN^[9] 算法,基于预测的 Bi-LSTM^[19] 算法,基于重构的 TAnoGAN^[12] 方法进行对比.研究采用异常检测领域内广泛认可的评价指标^[20],包括精确率 (Precision)、召回率 (Recall) 以及 F_1 分数.这些指标能够从多个维度综合反映算法在异常检测任务中的综合表现.由于异常现象往往难以被容忍,并且异常数据在整体数据中分布较少,判别异常比判别正常具有更高的重要性.因此,这里将异常值视为正例,即当正常类别被检测为异常

表 1 实验环境配置

Table 1 Setting of the experimental environment

软硬件平台	版本参数
CPU	AMD Ryzen 5700 X
GPU	NVIDIA Geforce RTX 4060
操作系统	Windows11
Python	3.9.18
Pytorch	2.1.1
CUDA	12.2

表 2 实验数据集数据分布情况

Table 2 Data distribution of experimental datasets

数据集	序列数	序列平均长度	$2\sigma/(%)$	$3\sigma/(%)$	异常占比/(%)
AWS	17	3985	4.46	1.35	9.32
DY	5	6665	0.098	0.098	0.44
RK	7	5210	0.71	0.22	0.79
ZK	4	8129	0.18	0.16	0.43

注 2σ 和 3σ 分别代表超过平均值2个标准差 (2σ) 和3个标准差 (3σ) 的数据点占比.

时, 记为真阳性 (TP).

各种算法的检测效果详见表 3 和图 11. 从整体性能角度分析, TiGAN 算法展现出不错的性能, 在所选数据集中均达到高水平表现. 具体而言, 在 RK, ZK, AWS 三个数据集上, TiGAN 均获得了最高的 F_1 分




图 9 算法检测效果显示

Fig. 9 Display of algorithm detection effect

数, 而在 DY 数据集中, 其 F_1 分数也接近最优值. 特别是在 ZK 数据集上, TiGAN 相比排名第二的算法, F_1 分数提升较大, 显示出显著的性能优势. 此外, 在多个数据集中, TiGAN 也实现了较高的召回率.

从算法的实用性角度考虑, 传统的基于统计和基于聚类的方法, 由于其固有的算法机制限制, 在单点异常的数据方面表现较好, 但在 ZK 和 AWS 等包含大量上下文异常的数据集中, 其检测性能会有所下降, 甚至失效. 与基于深度学习的其他方法相比, TiGAN 在检测效果上显示出更好的稳定性. 特别是在异常较为集中的 AWS 数据集中, TiGAN 不仅获得了最佳的 F_1 分数, 其召回率也保持在可接受的范围内, 说明插补结构对于异常集中现象有一定的抗干扰能力, 证明了其在实际卫星遥测参数异常检测中的潜力和可靠性.

3.3 消融实验

为验证在检测算法中引入对抗学习的必要性, 设计了两种实验设置: 一种包含特征学习模块 (对抗学习轮次设置为 10), 另一种不包含该模块 (对抗学习轮次设置为 0). 实验结果证明了结合 1DCNN 和 GAN 的数据分布特征学习模块对于提升检测算法性能的重要性 (见表 4). 结果表明, 特征学习模块与检测模块的协同作用是拟合复杂数据分布特征并实现高效异常检测的关键.

表 5 进一步给出在固定滑动时间窗口大小为 20 的情况下, 选择不同数量的插补点对检测结果的影响. 当插补数量设为 0, 即不进行插补时, 将其作为实验的对照组. 值得注意的是, 插补数量为 1 和 20 时分




图 10 不同方法生成数据效果对比

Fig. 10 Comparison of data generated by different methods

表 3 各种检测算法在数据集上的检测结果对比
Table 3 Comparison of detection results of various detection algorithms on datasets

数据集	指标	TiGAN	Z-score	LOF	DBSCAN	Bi-LSTM	TAnoGAN
DY	F_1	0.8824	0.7582	0.7018	0.4751	0.6955	0.8842
	Rec	0.7895	0.6106	0.5405	0.3115	0.9997	0.9411
	Pre	1.0000	1.0000	1.0000	1.0000	0.5332	0.8338
	Acc	0.9871	0.9961	0.9974	0.9932	0.5362	0.9913
RK	F_1	0.7595	0.5969	0.3435	0.4684	0.7430	0.7239
	Rec	0.7124	0.5418	0.8894	0.3788	0.9987	0.8131
	Pre	0.8133	0.6643	0.2128	0.6135	0.5916	0.6253
	Acc	0.9615	0.9883	0.8887	0.9805	0.6548	0.9566
ZK	F_1	0.8861	0.6846	0.2874	0.5495	0.4815	0.5160
	Rec	0.9159	0.7199	0.6445	0.4464	0.9970	0.9837
	Pre	0.8581	0.6526	0.1849	0.7143	0.3174	0.3498
	Acc	0.9823	0.9917	0.8707	0.9930	0.5534	0.8918
AWS	F_1	0.5470	0.2156	0.2039	0.1053	0.3755	0.3078
	Rec	0.8733	0.2714	0.7600	0.0563	0.8760	0.7909
	Pre	0.39818	0.1788	0.1177	0.8135	0.2390	0.1911
	Acc	0.6161	0.7861	0.3557	0.8960	0.3611	0.4064

注 加粗字体表示该指标下的最高值.




图 11 各种算法检测结果的 F_1 分数对比
Fig. 11 F_1 score comparison of detection results of various algorithms

别代表了预测和重构型方法. 实验结果表明, 插补数量对算法效果的影响并不具有明显规律, 但当插补数量为 10, 即时间窗口的一半时, 算法的效果较为稳定,

表 4 特征学习模块对检测结果影响的对比
Table 4 Comparison of the influence of feature learning modules on detection results

F_1 分数	有特征学习模块	无特征学习模块
序列1	0.6523	0.6132
序列2	0.6531	0.2203
序列3	0.8659	0.1403

之前的算法也都采用这个大小的插补来进行.

本文研究提出的 TiGAN 算法基于无监督学习方式, 旨在从未经标注卫星遥测参数中学习数据的分布模式. 这一学习过程的前提是异常数据占比较低, 对整体数据分布的影响较小. 因此, 通过设置不同的异常浓度的数据集, 展示异常数据在整体数据中所占比例对算法有效性的影响. 实验结果如图 12 所示, Z-score 方法和 DBSCAN 方法在异常浓度较高时效果显著下降, 甚至失效; 而 Bi-LSTM 和 LOF 方法在异常浓度较低时表现不佳; TAnoGAN 方法虽然整体表现较好, 但其效果波动较大. 本文提出的 TiGAN 算法在异常数据比例不超过 25% 的情况下展现出良好

表 5 插补数量对检测结果影响的对比
Table 5 Comparison of the influence of the number of interpolations on the test results

F_1 score	序列1	序列2	序列3
mask=0	0	0	0
mask=1	0.6429	0.4698	0.8552
mask=3	0.6523	0.5152	0.8552
mask=5	0.6523	0.3421	0.8670
mask=10	0.6523	0.6531	0.8659
mask=15	0.6132	0.6452	0.8670
mask=20	0.6523	0.2203	0.8479




图 12 不同的异常浓度对算法有效性的影响
Fig. 12 Display of algorithm detection effect

的检测效果,但是当异常数据比例超过 25% 时,其检测效果开始下降. 由于卫星遥测参数中异常数据的比例通常远低于 1%, TiGAN 算法能够在这种低异常浓度的环境中稳定运作,确保了其在实际应用中的可靠性和有效性.

4 结论

为解决现有基于深度学习的时间序列数据异常检测算法在卫星遥测参数检测任务中遇到的性能不足和对异常集中检测效果不佳的问题,本文提出一种基于时序插补的异常检测算法. 该算法结合了一维卷积神经网络和生成式对抗网络,通过对抗训练学习遥测参数的数据分布,有效建模了卫星遥测参数,并通过插补方法代替传统的预测或重构方法,有效消除复杂异常情况的影响,提高了检测算法的鲁棒性.

在卫星遥测数据集和相关公开数据集上的对比实验表明,所提出的方法在多个数据集上均展现出更

优的检测效果,显示出良好的适应性和鲁棒性. 在两个卫星数据集和一个公开设备异常检测数据集中,该方法取得了最高的 F_1 分数,相比次优方法有明显提升. 在第三个卫星数据集中,其性能也接近最优水平,差距仅为 0.002,进一步验证了该方法的鲁棒性与有效性. 此外,通过一系列对比消融实验,验证了对抗学习的必要性,找到插补窗口的最佳大小,并证明了算法在符合实际情况的异常浓度下均能有效发挥作用.

本文提出的方法在单点异常和上下文异常的检测中表现出色,为卫星运控人员提供了强有力的决策支持工具. 通过精确识别异常数据,有助于运控人员及时采取应对措施,保障卫星在轨安全可靠运行. 未来本文方法可以进一步扩展,建立准实时卫星健康状况评估体系,以期全天时不间断监控分析卫星遥测参数,实时检测并预警潜在的异常,为卫星运行管理提供更加全面和智能高效的支持.

参考文献

[1] WANG Chi. Developing space science vigorously to promote high-quality development of space activities in China[J]. *Bulletin of National Natural Science Foundation of China*, 2024, **38**(2): 363-364 (王赤. 大力发展空间科学 推动我国空间活动高质量发展 [J]. 中国科学基金, 2024, **38**(2): 363-364)

[2] WANG Chi, ZOU Ziming, HU Xiaoyan, et al. Big data in space science and great power of space[J]. *Chinese Science Bulletin*, 2024, **69**(9): 1132-1136 (王赤, 邹自明, 胡晓彦, 等. 空间科学大数据与航天强国 [J]. 科学通报, 2024, **69**(9): 1132-1136)

[3] XUE Yuxiong, YANG Shengsheng, BA Dedong, et al. Analyze of spacecraft system failures and anomalies attributed to the natural space radiation environment[J]. *Vacuum and Cryogenics*, 2012, **18**(2): 63-70 (薛玉雄, 杨生胜, 把

- 得东, 等. 空间辐射环境诱发航天器故障或异常分析 [J]. *真空与低温*, 2012, **18**(2): 63-70
- [4] WANG Yakun, YANG Kaifei, ZHANG Jie, *et al.* Case study of in-orbit satellite failures and artificial intelligence based failure detection[J]. *Chinese Space Science and Technology*, 2022, **42**(1): 16-29 (王亚坤, 杨凯飞, 张婕, 等. 卫星在轨故障案例与人工智能故障诊断 [J]. *中国空间科学技术*, 2022, **42**(1): 16-29)
- [5] WANG Yuze, LYU Liangqing, HE Rui. Spacecraft data definition method and tool design[J]. *Spacecraft Engineering*, 2024, **33**(1): 62-67 (王彧泽, 吕良庆, 何睿. 航天器数据定义方法及其工具设计 [J]. *航天器工程*, 2024, **33**(1): 62-67)
- [6] YANG Jiasen. Research on correlation Knowledge Discovery Method of Satellite Telemetry Data[D]. Beijing: Chinese Academy of Sciences (National Space Science Center, the Chinese Academy of Sciences), 2019 (杨甲森. 卫星遥测数据相关性知识发现方法研究 [D]. 北京: 中国科学院大学 (中国科学院国家空间科学中心), 2019)
- [7] CHIKODILI N B, ABDULMALIK M D, ABISOYE O A, *et al.* Outlier detection in multivariate time series data using a fusion of K-medoid, standardized euclidean distance and Z-score[C]//Proceedings of the 3rd International Conference on Information and Communication Technology and Applications. Minna: Springer, 2021: 259-271
- [8] TSIGKRITIS T, GROUMAS G, SCHNEIDER M. On the use of k -NN in anomaly detection[J]. *Journal of Information Security*, 2018, **9**(1): 70-84
- [9] SHERIDAN K, PURANIK T G, MANGORTEY E, *et al.* An application of DBSCAN clustering for flight anomaly detection during the approach phase[C]//Proceedings of the AIAA Scitech 2020 Forum. Orlando: AIAA, 2020: 1851
- [10] HU Zhichao, YU Xiangzhan, LIU Likun, *et al.* A time series anomaly detection method based on contextual generative adversarial network[J]. *Journal of Harbin Institute of Technology*, 2024, **56**(5): 1-11 (胡智超, 余翔湛, 刘立坤, 等. 基于上下文生成对抗网络的时间序列异常检测方法 [J]. *哈尔滨工业大学学报*, 2024, **56**(5): 1-11)
- [11] ZHOU T, MA Z Q, WEN Q S, *et al.* FEDformer: frequency enhanced decomposed transformer for long-term series forecasting[C]//Proceedings of the 39th International Conference on Machine Learning. Baltimore: PMLR, 2022: 27268-27286
- [12] BASHAR A, NAYAK R. TAnoGAN: time series anomaly detection with generative adversarial networks[C]//Proceedings of 2020 IEEE Symposium Series on Computational Intelligence. Canberra: IEEE, 2020: 1778-1785
- [13] LIN S Y, CLARK R, BIRKE R, *et al.* Anomaly detection for time series using VAE-LSTM hybrid model[C]//Proceedings of the ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona: IEEE, 2020. DOI: [10.1109/ICASSP40776.2020.9053558](https://doi.org/10.1109/ICASSP40776.2020.9053558)
- [14] PAPARRIZOS J, KANG Y H, BONIOL P, *et al.* TSB-UAD: an end-to-end benchmark suite for univariate time-series anomaly detection[J]. *Proceedings of the VLDB Endowment*, 2022, **15**(8): 1697-1711
- [15] DARBAN Z Z, WEBB G I, PAN S R, *et al.* Deep learning for time series anomaly detection: a survey[J]. *ACM Computing Surveys*, 2025, **57**(1): 15
- [16] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, *et al.* Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2014: 2672-2680
- [17] AHMAD S, LAVIN A, PURDY S, *et al.* Unsupervised real-time anomaly detection for streaming data[J]. *Neurocomputing*, 2017, **262**: 134-147
- [18] XU S Y, LIU H Y, DUAN L T, *et al.* An improved LOF outlier detection algorithm[C]//Proceedings of 2021 IEEE International Conference on Artificial Intelligence and Computer Applications. Dalian: IEEE, 2021: 113-117
- [19] MISHRA S, KSHIRSAGAR V, DWIVEDULA R, *et al.* Attention-based Bi-LSTM for anomaly detection on time-series data[C]//Proceedings of the 30th International Conference on Artificial Neural Networks. Bratislava: Springer, 2021: 129-140
- [20] ZHAO Yuwei, SU Ju. Satellite anomaly detection method based on parameter adaptive optimization clustering[J]. *Chinese Journal of Space Science*, 2023, **43**(5): 927-937 (赵玉炜, 苏举. 基于参数自适应优化聚类的卫星状态异常检测方法 [J]. *空间科学学报*, 2023, **43**(5): 927-937)

作者简介



杜晓龙 男, 2000年6月出生于河南省南阳市, 现为中国科学院国家空间科学中心在读硕士研究生, 主要研究方向为卫星智能运控技术、卫星健康管理等。
E-mail: duxiaolong22@mailsucas.ac.cn



白萌 女, 1987年6月出生, 高级工程师, 中国科学院国家空间科学中心运控部副主任, 青促会会员。全面主持空间科学卫星在轨运行管理, 长期深耕于智能运控技术研究。
E-mail: baimeng@nssc.ac.cn