

基于对抗自编码器与时空特征融合的卫星 遥测参数异常检测方法*

王业昕^{1,2} 肖志刚¹

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

摘要 遥测参数是地面运控系统判断卫星在轨工作性能和健康状态的重要依据,具有强相关性、伪周期性、噪声与缺失值并存等特点。传统方法难以同时刻画遥测数据的时序特征和参数间依赖关系,对复杂异常的识别能力有限。针对上述问题,本文提出一种基于对抗自编码器与时空特征融合的异常检测方法。该方法首先利用时间卷积网络提取多尺度时序特征,通过相似度计算构建参数间长期依赖结构,并结合嵌入向量与窗口输入学习短期交互结构,随后利用图神经网络建模参数间依赖关系,并在对抗训练框架下引入改进自编码器,增强模型对噪声扰动和缺失数据的鲁棒性。真实卫星数据和公开数据集的实验结果表明,该方法能够提升遥测参数异常检测的准确性与鲁棒性。

关键词 遥测参数 多变量时间序列 异常检测 对抗自编码器 时空特征融合
中图分类号 V474

Anomaly Detection Method for Satellite Telemetry Parameters Based on Adversarial Autoencoders and Spatiotemporal Feature Fusion

WANG Yexin^{1,2} XIAO Zhigang¹

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

2 (University of Chinese Academy of Sciences, Beijing 100049)

Abstract Satellite telemetry parameters are an important source of information for ground operation and control systems to evaluate the on-orbit performance and health status of spacecraft. These parameters are generated by onboard sensors and controllers and can be regarded as typical multivariate time series data, characterized by strong correlations, quasi-periodicity, noise, and missing values. Traditional methods have difficulty simultaneously capturing the temporal characteristics of telemetry data and the dependency relationships among parameters, which limits their ability to identify complex anomalies in practical scenarios. To address the limitations of existing methods in multivariate telemetry anomaly detection, this paper proposes an anomaly detection method based on adversarial autoencoders and spatiotemporal feature aggregation. The

* 科技创新2030—“量子通信与量子计算机”重大项目“中高轨量子科学实验卫星”项目地面支撑系统任务(E4314A0202)资助

投稿日期: 2025年12月14日

E-mail: wangyexin23@mailsucas.ac.cn

proposed method adopts an adversarial autoencoder as the overall framework and uses adversarial training to enhance the robustness of the model under noise disturbances and missing data. Meanwhile, a spatiotemporal feature aggregation block is introduced into both the encoder and the discriminator. Specifically, a temporal convolutional network is used to extract multiscale temporal features from telemetry sequences. Long-term dependency structures among parameters are then constructed through similarity calculation, while short-term interaction structures are learned by combining embedding vectors with sliding-window inputs. A graph neural network is further used to model dependency relationships among parameters, enabling the joint representation of temporal variation information and inter-parameter correlation information. In the anomaly detection stage, an anomaly score is constructed by combining reconstruction error and discriminator output, so as to identify anomalous samples more effectively. Experimental results on real satellite telemetry data and public datasets show that the proposed method can improve the ability to distinguish normal samples from anomalous samples. On the SWaT, BIRDS, and DY datasets, the F1-score of the proposed method is improved by approximately 1%–7% compared with the best-performing baseline methods, demonstrating its accuracy, robustness, and applicability in multivariate telemetry anomaly detection.

Key words Telemetry parameters, Multivariate time series, Anomaly detection, Adversarial autoencoder, Spatiotemporal feature fusion

0 引言

卫星作为多学科尖端技术集成的大型复杂系统，其安全性至关重要^[1,2]。卫星遥测系统以特定周期采集星载设备各部件的工作状况和参数信息，采集到的数据经过模数转换、编码、调制等处理后下传至地面接收站，地面接收后再经相应处理得到遥测参数^[3]。地面运控系统通过对遥测参数进行监测，为卫星安全稳定运行和延长服役周期提供重要保障。

传统的卫星遥测参数异常检测方法，如基于阈值和基于专家系统的方法^[4]，在面对隐蔽性较强或未知类型的异常模式时检测能力有限。因此，利用传统机器学习方法^[5-7]和深度学习方法挖掘遥测参数中蕴含的信息，已成为保障在轨卫星可靠运行的重要研究方向。NASA首次将 LSTM 和非参数阈值方法结合用于航天器遥测异常检测，在 SMAP 和 MSL 两个公共数据集上取得了较好的效果^[8]。然而，该方法需要为每个遥测参数建立独立的通道模型，在面对高维数据时效率较低，且难以捕获跨通道的多变量异常。针对多变量时间序列场景，OmniAnomaly^[9]构建了由门控递归单元和变分自编码器组成的随机递归神经网络，用于学习多变量时间序列的正常模式，并利用重构概率判断异常；Anomaly Transformer^[10]通过 Transformer 的自注意力机制获取各时间点之间的时序关联，利用“全局关联”和“局部关联”的差异刻画异常。然而，上述方法并不完全适用于卫星遥测参数异常检测场景，卫星各系统传感器参数之间通常存在复杂而强烈的依赖关系，若能准确建模参数之间的相关性，有望进一步提高异常检测的准确性和效率。因此，同时考虑遥测数据中的时空特征对提升卫星遥测参数异常检测性能具有重要意义。图神经网络^[11]在建模空间相关性方面具有明显优势^[12]，已广泛应用于多变量时间序列研究，如 MTAD-GAT^[13]、GDN^[14]等。基于此，本文采用时间卷积网络（TCN）和图神经网络（GNN）进行时间特征的提取与空间信息的聚合。

在异常检测研究中，近年来提出了一些能够挖掘多变量特征的深度生成模型。例如，MAD-GAN^[15]提出了一种基于生成对抗网络的无监督多变量异常检测方法，在 GAN 中使用 LSTM-RNN 作为基本模型，通过生成器和判别器的对抗过程检测时间序列中的异常数据。杜晓龙^[16]等利用生成式对抗网络对正常卫星遥测参数进行建模，并采用时序插补策略检测异常情况，避免了传统基于重构或预测的方法在复杂场景下检测结果不佳的问题。结合卫星

遥测参数高维、非线性、高噪声和数据缺失等特点,受上述研究启发,本文采用对抗训练策略以增强模型对噪声和缺失数据的鲁棒性。

本文设计了一种面向卫星多变量遥测参数的异常检测算法。该方法针对遥测参数高噪声和数据缺失问题,引入对抗学习思想和自编码器架构,构建了改进的对抗自编码器网络;同时利用 TCN 提取多尺度时间特征,并结合 GNN 建模参数间依赖关系,综合考虑遥测参数中的时空特征,从而提高异常检测性能。

1 卫星遥测参数异常检测问题

1.1 遥测参数异常分类

异常通常表现为遥测参数中多个遥测变量的异常值或异常子序列,包括单变量点异常和多变量异常等,如图 1 所示。单变量点异常通常表现为某一参数在瞬时发生突变,例如单粒子事件导致传感器故障,进而引起单一参数跳变,这类异常通过对部分关键遥测参数设置报警门限即可检测出来;多变量异常涉及多个参数之间的相关关系与联合变化模式,从单个变量来看,各参数可能均未超出异常阈值,但参数组合关系已偏离正常运行规律,属于较为常见但不易检测的异常类型。




图 1 单变量异常与多变量异常示意图 (高亮表示异常区间)

Fig.1 Schematic Illustration of Univariate and Multivariate Anomalies (Highlighted Areas Indicate Anomalous Intervals)

在卫星遥测参数异常检测中,单变量异常通常仅针对部分关键参数,难以对卫星整体或部件状态进行全面评估,且当卫星内部设计和功能发生变化时,就需要重新设置门限。同时,多变量异常使用简单的阈值法往往会出现漏报,难以实现对卫星整体运行状态的综合评估。因此,本文关注上述异常类型,从单个参数的时间变化模式与多个参数间的依赖关系两个维度出发,综合建模遥测参数的时间与空间特征,以提升多变量异常的检测能力。

1.2 遥测参数异常检测问题定义

卫星遥测参数可表示为长度为 T 、维度为 N 的多变量时间序列 X :

$$X = \{x^{(t)}\}_{t=1}^T, x^{(t)} \in \mathbb{R}^N \quad (1)$$

其中, $x^{(t)}$ 表示时刻 t 的遥测向量,包含 N 个遥测参数。数据集 X 被划分为训练集、验证集和测试集:

$$X_{train} = \{x^{(t)}\}_{t=1}^{T_1}, X_{valid} = \{x^{(t)}\}_{t=T_1+1}^{T_1+T_2}, X_{test} = \{x^{(t)}\}_{t=T_1+T_2+1}^T \quad (2)$$

其中,训练集仅包含正常运行样本,用于学习正常数据的特征模式;验证集用于模型调参与参数选择;测试集可能包含异常数据,用于评估模型性能。

为刻画时间依赖关系,采用长度为 w 的滑动窗口对 X 进行分割,构造窗口子序列样本:

$$X_{seq}^{(t)} = [x^{(t-w+1)}, x^{(t-w+2)}, \dots, x^{(t)}] \in \mathbb{R}^{w \times N} \quad (3)$$

模型以窗口子序列 $X_{seq}^{(t)}$ 为输入,对当前时刻 t 的观测向量 $x^{(t)}$ 生成异常分数 $s^t \in \mathbb{R}$,并通过将异常分数与阈值 $\tau(t)$ 进行比较实现异常判定:

$$\hat{y}^{(t)} = \begin{cases} 1, & s^t > \tau(t) \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

其中, $\hat{y}^{(t)} = 1$ 表示时刻 t 存在异常, $\hat{y}^{(t)} = 0$ 表示正常。




图 2 遥测参数异常检测问题示意图

Fig.2 Schematic Illustration of the Telemetry Parameter Anomaly Detection Problem

因此，本文的目标是利用正常状态下的遥测参数数据构建异常检测模型，从而实现对输入子序列对应时刻的异常判定。

2 卫星遥测参数异常检测方法

2.1 基于对抗自编码器的模型框架

本文构建的基于对抗自编码器的异常检测模型由编码器Enc、生成器Gen和判别器Disc三部分组成，整体流程包括训练阶段和异常检测阶段。编码器和判别器均采用由TCN和GAT构成时空特征聚合块作为核心网络结构，用于提取时序动态特征和参数之间的依赖关系。生成器采用多层感知器MLP结构，负责将低维表示映射回原始数据空间，实现对正常样本的重构。




图 3 训练阶段和异常检测阶段模型架构图

Fig.3 Model Architecture in the Training Phase and Anomaly Detection Phase

训练阶段模型整体架构如图3上图所示，训练样本 X_{train} 经过编码器Enc压缩编码为低维向量表示 z ，再由生成器Gen重构为生成样本 $\hat{X} = G(z)$ ，该过程使模型能够学习正常样本的潜在表示及其重构规律。同时，引入随机潜在向量表示 $Random\ \tilde{z}$ ，并通过生成器Gen得到随机生成样本 $\tilde{X} = G(Random\ \tilde{z})$ ，用于增强判别器Disc的泛化能力和对异常样本的识别能力。原始训练样本 X_{train} 、重构样本 $G(z)$ 和随机生成样本 $\tilde{X}$ 同时输入判别器Disc进行判别，判别器Disc的输出 $D(\hat{X})$ 、 $D(X_{train})$ 和 $D(\tilde{X})$ 分别表示生成样本 $G(z)$ 、原始样本 X_{train} 以及随机生成样本 $G(Random\ \tilde{z})$ 被正确识别的置信度。

模型的优化目标由重构损失和判别损失两部分组成。重构损失 L_R 用于约束编码器Enc和生成器Gen对正常样本的重构能力，其定义为输入样本 X_{train} 与重构样本 $\hat{X}$ 的残差，表达

式如下：

$$Loss_R = \mathbb{E}_{X \sim P_X} [MAE(X_{train} - \hat{X})] = \mathbb{E}_{X \sim P_X} \left[\frac{1}{N} \sum_{i=1}^N |X_{train_i} - \hat{X}_i| \right] \quad (5)$$

判别损失 L_D 用于优化判别器，其表达式为：

$$Loss_D = \mathbb{E}_{X \sim P_X} [-|D(X_{train}) - D(\hat{X})| + \varepsilon \cdot \max(D(X_{train}) - D(\hat{X}), 0)] \\ + \mathbb{E}_{\tilde{X} \sim P_{\tilde{X}}} [-|D(X_{train}) - D(\tilde{X})| + \varepsilon \cdot \max(D(X_{train}) - D(\tilde{X}), 0)] \quad (6)$$

判别损失的负号项使判别器最大化正样本和负样本的判别分数差距，从而增强判别器的区分能力。判别损失的 $\varepsilon \cdot \max(D(X_{train}) - D(\hat{X}), 0)$ 和 $\varepsilon \cdot \max(D(X_{train}) - D(\tilde{X}), 0)$ 通过 $\max(\cdot, 0)$ 形成间隔约束项，强制满足 $D(X_{train}) < D(\hat{X})$ 以及 $D(X_{train}) < D(\tilde{X})$ 的约束关系。

如图3下图所示，在异常检测阶段仅需输入测试数据，无需对随机潜在表示 $\tilde{X}$ 和重构数据 $\hat{X}$ 的判别。本文结合重构误差与判别器输出构建异常评分，对于编码器与生成器部分，异常分数基于原始样本与生成样本之间的平均绝对误差设计为重构误差值；对于判别器部分，其输出的判别分数可以直接用作异常分数：

$$S_{i,t} = |X_{i,t} - \hat{X}_{i,t}| + \rho \cdot D(X) \quad (7)$$

其中 ρ 为调节系数， $S_{i,t}$ 表示 t 时刻参数 i 的异常评分。为了消除不同变量尺度差异，本文参照文献^[14]中的处理方式对异常评分进行标准化处理：

$$\hat{S}_{i,t} = \frac{S_{i,t} - \mu}{\sigma} \quad (8)$$

在此基础上，本文在每一时刻 t 选取所有变量中的最大异常评分作为该时刻的最终异常评分：

$$S_t = \max_i \{\hat{S}_{i,t}\} \quad (9)$$

将超出阈值的时刻判定为异常时间点，将异常评分较高的变量定位为异常来源，阈值选取为最优性能时给定的全局阈值。

2.2 时空特征聚合块

2.2.1 时间信息

如1.2节所述，在时刻 t ，模型输入为长度为 w 的历史窗口子序列 $X_{seq}^{(t)} = [x^{(t-w+1)}, x^{(t-w+2)}, \dots, x^{(t)}] \in \mathbb{R}^{w \times N}$ ，一个时间窗口内的数据同时包含时间特征和空间特征，本文首先利用时间卷积网络TCN提取窗口序列 $X_{seq}^{(t)}$ 的时间特征。

TCN以一维卷积为基本结构，为确保隐藏层输出与输入序列长度一致，并避免未来信息泄漏，本文采用仅在左侧进行零填充的因果卷积结构，如图4所示。为在有限层数下扩大感受野，TCN进一步在标准特征图中引入间隔采样的扩张卷积机制，以增强模型对长时间时序特征的建模能力，如图5所示。




图4 因果卷积示意图

Fig.4 Schematic Illustration of Causal Convolution




图 5 扩张卷积示意图

Fig.5 Schematic Illustration of Dilated Convolution

为更好地建模遥测数据不同时间尺度下的变化模式, 本文设计多尺度时间特征提取模块, 采用 1×2 、 1×3 、 1×6 和 1×7 多卷积核并行提取时间特征, 并在通道维度进行拼接融合, 其计算过程可表示为:

$$y^{(t)} = \text{concat} \left(X_{seq}^{(t)} * f_{1 \times 2}, X_{seq}^{(t)} * f_{1 \times 3}, X_{seq}^{(t)} * f_{1 \times 6}, X_{seq}^{(t)} * f_{1 \times 7} \right) \quad (10)$$

经过上述时间特征提取模块后, 可得到时刻 t 对应的时间特征表示 $y^{(t)} := [y^{(t-w+1)}, y^{(t-w+2)}, \dots, y^{(t)}]$ 。在此基础上, 进一步利用图神经网络对遥测参数之间的关联关系进行建模, 从而实现时间特征与空间特征的聚合。

2.2.2 空间信息

对于多变量遥测序列 $x^{(t)} \in \mathbb{R}^N$, 可将其视为一个具有 N 个节点的图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, 其中每个节点代表一个遥测参数, 每条边表示两个参数之间的相关关系。考虑到卫星系统中各参数之间的依赖关系在时间维度上保持相对稳定, 且为了在没有先验知识的情况下量化相关性, 本文采用数据驱动的方式学习参数之间的长期依赖结构。

首先, 从训练数据中截取时间长度为 d 的序列片段 $M \in \mathbb{R}^{N \times d}$, 然后通过余弦相似度 $S(\cdot)$ 计算参数间的相关性:

$$S(i, j) = \frac{M_i \cdot M_j^T}{|M_i| \cdot |M_j|} \quad (11)$$

其中 $S(i, j) \in [-1, 1]$ 表示节点 i 和 j 的相似度得分。最后, 对每个图节点选取相似度最高的前 K 个图节点构建邻接关系, 图结构可形式化定义为:

$$\mathcal{G} = (\mathcal{V}, \mathcal{E}), \quad \mathcal{V} = \{1, 2, \dots, N\}, \quad \mathcal{E} = \{(i, j) | j \in \text{top}K(S(i, :)), i = 1, \dots, N\} \quad (12)$$

为获得可训练的空间表示, 本文为每个遥测参数引入节点嵌入向量 $v_i \in \mathbb{R}^d, i \in \{1, 2, \dots, N\}$ 表示各遥测参数的内在属性, 嵌入向量随机初始化, 并与模型的其余参数一起训练共同更新。在时间步 t , 图注意力网络将节点嵌入向量 v_i 与对应的时间特征 $y_i^{(t)}$ 连接起来, 并据此计算节点间的注意力系数:

$$\hat{a}_{i,j} = \text{LeakyReLU} \left((v_i \oplus W y_i^{(t)}) \oplus (v_j \oplus W y_j^{(t)}) \right) \quad (13)$$

$$a_{i,j} = \frac{\exp(\hat{a}_{i,j})}{\sum_{k \in \mathcal{N}_i} \exp(\hat{a}_{i,k})} \quad (14)$$

其中 $\oplus$ 表示连接操作, W 是权重矩阵, LeakyReLU 是非线性激活函数, $\hat{a}_{i,j}$ 表示节点 i 和节点 j 之间在归一化之前的注意力得分, $a_{i,j}$ 是使用 softmax 对注意力系数进行归一化之后的结果。

计算出注意力系数 $a_{i,j}$ 后, 将其与 $\mathcal{G}$ 中的 $\mathcal{E}$ 相结合形成最终边权 $e_{i,j}$:

$$e_{i,j} = a_{i,j} \cdot \epsilon_{i,j} \quad (15)$$

其中 $\epsilon_{i,j} \in \{0, 1\}$ 表示由 top-K 筛选得到的结构化邻接信息。

最后, 以时间特征 $y^{(t)}$ 作为图神经网络各节点的原始输入, 结合边权 $e_{i,j}$ 对邻居节点信息进行聚合, 从而更新节点 i 在时刻 t 的特征表示 $z_i^{(t)}$:

$$z_i^{(t)} = \sigma \left(\sum_{j \in \mathcal{N}_i} e_{i,j} W y_j^{(t)} \right) \quad (16)$$

其中, σ 表示sigmoid激活函数, $\mathcal{N}_i$ 为节点 i 的邻居集合, W 为可训练权重矩阵。

从上述时空特征聚合过程, 模型获得了融合时空信息的表示 $\{z_1^{(t)}, \dots, z_N^{(t)}\}$, 将各节点表示进行拼接, 得到全局特征表示 g , 并将其作为编码器的输出输入到生成器中进行重构。




图 6 时空特征聚合块

Fig.6 Structure of the Spatiotemporal Feature Aggregation Block

3 实验结果与分析

3.1 数据集及预处理

实验选取了三个数据集: 公开的遥测数据集 BIRDS, 用于领域内模型的横向对比; 自建遥测数据集 Space_DY, 用于验证模型在真实工程场景下的性能; 公开的多变量工业数据集 SWaT, 用于评估模型的异常检测泛化能力。所有数据均采用最小-最大归一化映射到 $[0,1]$ 区间内。

公开遥测数据集 BIRDS 包含四颗 IU CubeSat 卫星的太阳能电池板遥测参数(温度、电流、电压等), 能够较好反映卫星电力系统对异常检测的需求。我们参照文献^[17]定义的异常判定标准, 对该数据集进行了标签标注和数据划分。

遥测数据集 Space_DY 来自我国某空间科学卫星 2024 年 11 月的电源数据包延时遥测数据, 所有数据均采集于真实飞行任务过程。根据卫星运行技术文档与专家经验, 从原始数据包中筛选出涵盖电源分系统关键参数的 27 维特征, 经过下采样后获得共计 6 万余条数据, 并根据地面测控日志、异常事件报告以及工程阈值规则完成异常标注。

工业数据集 SWaT 源自新加坡科技与设计大学网络安全中心开展的供水系统和水安全处理系统攻击测试, 数据采集自 51 个传感器连续 11 天的运行过程。虽然 SWaT 属于工业控制系统领域, 但其多参数时间序列的数据结构与卫星遥测参数相似, 且作为业界公认的异常检测基准数据集, 能够用于评估模型在其他领域异常检测任务中的泛化能力。

3.2 实验环境及模型参数配置

本文所有实验的运行环境为 CPU AMD Ryzen 5700X, GPU NVIDIA GeForce RTX 4090, 操作系统 Ubuntu 20.04, Python-3.10.15, PyTorch-2.1.1。

在输入数据方面, 原始时间序列被划分为多个固定长度的窗口子序列, 步长设置为 1。网络架构方面, TCN 的扩张因子为 2, 其层数根据窗口大小通过公式自适应确定。同时, 时序卷积网络并行使用四个一维卷积核, 其大小分别设置为 2、3、6 和 7, 各卷积层的输出在通道维度上进行拼接, 以融合多尺度特征。在图神经网络部分, 节点嵌入向量的维度为 64, 并采用比例为 0.2 的 Dropout 机制以增强泛化能力。编码器输出的全局表示向量维度为 500。模型训练采用 Adam 优化器, 初始学习率设为 1×10^{-3} , 批大小为 32, 训练轮数为 100, 并引入早停策略以防止过拟合。

3.3 实验结果与对比分析

为了评估本文所提方法的性能,选取了同领域广泛使用的统计方法(主成分分析PCA)、机器学习方法(孤立森林IF)、传统深度学习方法(LSTM)和最近基于深度学习的复杂组合模型(LSTM-VAE、GDN、MTAD-GAT、USAD)进行对比。研究采用在异常检测领域被广泛认可的评估指标:精确率(Precision)、召回率(Recall)和F1分数(F1-score),表1给出了各模型在参数设置最优情况下的检测结果,每个数据集中指标的最高值被加粗强调。

表1 不同方法的异常检测结果对比

Table 1 Comparison of Anomaly Detection Results for Different Methods

数据集	SWaT			BIRDS			Space_DY		
指标	P	R	F1	P	R	F1	P	R	F1
PCA	0.185	0.860	0.305	0.738	0.404	0.522	0.526	0.849	0.650
IF	0.239	<u>0.777</u>	0.366	0.597	0.344	0.435	0.665	0.827	0.737
LSTM	0.994	0.409	0.580	<u>0.987</u>	0.145	0.252	0.998	0.258	0.410
LSTM-VAE	0.986	0.662	0.791	0.582	0.772	0.664	0.929	0.783	0.850
GDN	0.994	0.681	0.808	0.480	0.998	0.649	0.826	0.869	0.846
MTAD-GAT	0.965	0.753	<u>0.846</u>	0.989	0.644	<u>0.781</u>	0.784	0.999	<u>0.879</u>
USAD	<u>0.996</u>	0.657	0.792	0.536	0.671	0.596	0.557	0.769	0.646
Ours	0.997	0.760	0.863	0.721	<u>0.997</u>	0.837	<u>0.972</u>	<u>0.941</u>	0.956

F1分数作为Precision和Recall的调和平均,能够综合反映模型在误报与漏报能力之间的整体表现。如表1所示,本文方法在三个数据集上均取得最佳F1分数,较最优基线分别提升1.7%、5.6%和7.7%。在SWaT中,LSTM的Precision虽然是0.994,但Recall仅为0.409,说明其对异常样本存在较高漏检率;相比之下,本文方法在保持高Precision的同时提升Recall至0.760,F1达到最优。在BIRDS中,本文方法的Recall为0.997,明显高于其他方法,说明其对相关性异常具有较强的检出能力。虽然Precision为0.721存在误报优化空间,但在卫星遥测场景中,提高异常检出率具有更强的实际意义。相比之下,GDN的Recall虽然达到0.998,但Precision仅为0.480,导致其F1分数偏低。在Space_DY中,本文方法在三项指标上均保持相对较高水平。

从方法特性来看,时间信息对于时间序列异常检测至关重要,PCA和孤立森林表现不佳主要是因为它们只适用于数值异常,缺乏提取时间特征的能力;相比仅依赖建模时间依赖的LSTM和LSTM-VAE等方法,本文模型在BIRDS数据集的Recall上表现更优,说明空间相关性建模对于遥测参数异常识别具有重要作用。GDN、MTAD-GAT和我们的方法都是基于图结构的异常检测方法,然而前两种方法对不同的异常场景和噪声很敏感,对未知异常的建模能力较弱。

3.4 消融实验

为了验证图结构学习策略的有效性,本文设计了一组消融实验,将本文基于相似度构建的图结构替换为随机初始化结构。如表2所示,随机初始化图结构相当于为各参数节点随机分配邻居节点,这种随机性引起的噪声会干扰模型对真实参数依赖关系的学习,导致模型性能在所有数据集上均有下降。

表2 不同图结构学习策略的影响对比

Table 2 Comparison of the Effects of Different Graph Structure Learning Strategies

F1-score	SWaT	BIRDS	Space_DY
随机初始化图结构	0.703	0.709	0.783
Ours	0.863	0.837	0.956

为了验证模型同时聚合空间特征与时间特征的必要性,本文设计了两组消融实验,分别

移除时间建模模块和空间建模模块。实验结果如表 3 所示，仅使用单一特征时性能均有降低，说明两个模块组合使用对于刻画复杂数据的时序分布特征和参数间相关性具有重要作用，是实现高效异常检测的关键。近年来，卫星遥测参数异常检测研究主要集中于时间维度，对周期性、趋势等时间相关性的探索已较为成熟，而对参数间依赖关系的研究相对不足。然而，卫星各系统传感器之间通常存在复杂而强烈的关联关系⁰，值得更多的关注和应用。

表 3 不同特征模块的影响对比

F1-score	SWaT	BIRDS	Space_DY
只使用空间信息	0.721	0.812	0.876
只使用时间信息	0.665	0.534	0.817
Ours	0.863	0.837	0.956

3.5 鲁棒性实验

真实遥测参数受空间电磁与辐射干扰、通信带宽限制、网络信道拥堵及地面接收站覆盖不全等因素影响，往往存在不同程度的数据缺失。为验证模型对缺失数据的鲁棒性，本文在原始数据中随机删除 15% (rate=0.15) 和 30% (rate=0.3) 的数据，并通过线性插值对缺失数据进行填充。实验结果表明，即使在丢失数据的情况下，模型的异常检测性能也未出现明显下降。




图 7 不同数据缺失率下模型性能对比

Fig.7 Model Performance Under Different Missing Data Rates

3.6 定性分析

为分析时间依赖建模模块提取特征的可分性，本文采用 t-SNE 对多尺度时间特征进行可视化，如图 8 所示，不同参数在特征空间中呈现明显的局部聚集现象，说明模型提取的时间特征能够在一定程度上反映局部参数之间的行为相似性。




图 8 多尺度时间特征的 t-SNE 可视化结果

Fig.8 t-SNE Visualization of Multi-Scale Temporal Features

基于 BIRDS 测试集，本文对两个关键遥测参数的生成器重构结果进行可视化，其中一个参数包含异常区间，另一个参数为正常数据。如图 9 所示，在正常区间，重构结果与原始数据变化趋势基本一致，且整体较为稳定；在高亮标注的异常区间内，重构数据与原始异常

数据之间产生显著偏差。此外，由于自编码器对原始数据中的噪声干扰具有一定抑制作用，重构数据相比原始数据具有更高的平滑度。




图 9 原始数据与生成器重构输出对比图（高亮表示异常区间）

Fig.9 Comparison Between Raw Data and Generator Reconstruction Output (Highlighted Areas Indicate Anomalous Intervals)

图 10 展示了 BIRDS 数据集正常样本与异常样本异常分数的概率密度分布，其中蓝色曲线代表正常样本，红色曲线代表异常样本。如图 10 所示，模型对正常样本的异常分数估计较为集中，主要分布在接近 1 的区域，并呈现出较尖锐的峰值。相对地，异常样本的异常分数分布较为分散。这种分布差异表明模型能够有效区分正常样本与异常样本，此外，异常样本异常分数分布呈现出多峰特性，在一定程度上反映了异常模式的多样性和复杂性。




图 10 异常分数分布的核密度估计图

Fig.10 Kernel Density Estimation of Anomaly Score Distributions

3.7 计算复杂度分析

为评估本文方法的计算开销与运行效率，本文将其与 3.3 节中的几种典型方法进行比较。考虑到不同模型在网络结构和实现方式上存在差异，本文统一以时间窗口长度 L ，变量个数 N 、每个节点保留的邻居数 K 和隐藏维度 d 表示输入规模与特征维度。在忽略常数项及部分实现细节的条件下，表 4 给出了各方法训练阶段的主导计算复杂度，并列出了其在 BIRDS 数据集上的单位样本推理时间。

由表 4 可知，LSTM、LSTM-VAE 和 USAD 主要依赖时序建模或重构过程，计算复杂度相对较低；GDN、MTAD-GAT 和本文方法由于引入了变量关联建模，复杂度中包含与变量间关系计算相关的 N^2 项，因此计算开销有所增加。进一步结合推理时间来看，USAD 的推理时间最短；GDN、MTAD-GAT 和本文方法的推理时间处于同一量级，其中本文方法低于 GDN，略高于 MTAD-GAT，整体推理开销仍保持在较低水平。结合前文实验结果可以看出，本文方法在增加一定计算代价的同时取得了更好的检测性能，在检测效果与运行效率之间取得了较好的平衡。

表 4 不同方法训练阶段计算复杂度与单位样本推理时间比较

Table 4 Comparison of Training Computational Complexity and Per-Sample Inference Time for Different

Methods		
方法	训练阶段主导计算复杂度	单位样本推理时间 (s)

LSTM	$O(Ld^2 + LNd)$	$5.70 \pm 1.76 \times 10^{-7}$
LSTM-VAE	$O(Ld^2 + LNd)$	<u>$4.31 \pm 0.047 \times 10^{-7}$</u>
GDN	$O(LNdK + N^2d)$	$5.15 \pm 2.44 \times 10^{-6}$
MTAD-GAT	$O(LN^2d + L^2Nd + Ld^2)$	$1.75 \pm 0.33 \times 10^{-6}$
USAD	$O(L^2N^2 + LNd)$	$1.32 \pm 0.04 \times 10^{-7}$
Ours	$O(LN^2d + Ld^2)$	$2.38 \pm 0.41 \times 10^{-6}$

注：单位样本推理时间为各方法在 BIRDS 数据集上重复测试 10 次所得结果的平均值±标准差。

4 结论

本文针对卫星遥测参数异常检测提出了一种结合对抗自编码器、时间卷积网络与图神经网络的多变量异常检测方法。该方法从时间特征与空间特征两个维度对遥测参数进行联合建模，充分挖掘正常模式下的内在规律，并通过对抗训练有效增强了模型对复杂噪声与缺失数据的适应性。实验验证了其在遥测参数异常检测中优于传统方法的检测性能与稳定性，是提升卫星遥测参数异常检测精度的有效途径，为保障在轨卫星安全运行提供了可行的技术方案。

参考文献

- [1] 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, 张健, 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)
- [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] WANG Yuze, LYU Liangqing, HE Rui. Spacecraft data definition method and tool design[J]. *Spacecraft Engineering*, 2024, **33**(1): 62-67 (王戡泽, 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)
- [4] LI Zhenyu, SONG Yuchen, PENG Xiyuan, *et al.* Contrastive time-series reconstruction method for satellite anomaly detection[J]. *Chinese Journal of Scientific Instrument*, 2024, **45**(4): 17-26 (李桢煜, 宋宇晨, 彭喜元, 等. 基于对比序列重构的卫星遥测数据异常检测方法[J]. 仪器仪表学报, 2024, **45**(4): 17-26)
- [5] GU Xinyu. Research on Satellite Telemetry Data Prediction Based on ARIMA-SVR Combined Model[D]. Beijing: National Space Science Center, CAS, 2021 (顾昕雨. 基于 ARIMA-SVR 组合模型的卫星遥测数据预测研究[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2021)
- [6] 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. DOI: 10.11728/cjss2023.05.2022-0054 (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. DOI: 10.11728/cjss2023.05.2022-0054)
- [7] HE Jiahui, CHENG Zhijun, GUO Bo. Telemetry anomaly detection method based on joint dictionary learning and OCSVM[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, **44**(13): 327931. DOI: 10.7527/S1000-6893.2022.27931 (何家辉, 程志君, 郭波. 联合字典学习与 OCSVM 的遥测数据异常检测方法[J]. 航空学报, 2023, **44**(13): 327931. DOI: 10.7527/S1000-6893.2022.27931)
- [8] 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: ACM, 2018. DOI: 10.1145/3219819.3219845
- [9] SU Ya, ZHAO Youjian, NIU Chenhao, *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: ACM, 2019. DOI: 10.1145/3292500.3330672
- [10] XU J H, WU H X, WANG J M, *et al.* Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy[C]//International Conference on Learning Representations. 2022

- [11] JIN M, KOH H Y, WEN Q S, *et al.* A survey on graph neural networks for time series: forecasting, classification, imputation, and anomaly detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, **46**(12): 10466-10485. DOI: 10.1109/TPAMI.2024.3443141
- [12] TANG C F, XU L J, YANG B, *et al.* GRU-based interpretable multivariate time series anomaly detection in industrial control system[J]. *Computers & Security*, 2023, **127**: 103094. DOI: 10.1016/J.COSE.2023.103094
- [13] ZHAO H, WANG Y J, DUAN J Y, *et al.* Multivariate time-series anomaly detection via graph attention network[C]//2020 IEEE International Conference on Data Mining. Sorrento: IEEE, 2020. DOI: 10.1109/ICDM50108.2020.00093
- [14] DENG A L, HOOI B. Graph neural network-based anomaly detection in multivariate time series[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI Press, 2021, 35(5), 4027-4035
- [15] LI D, CHEN D C, JIN B H, *et al.* MAD-GAN: multivariate anomaly detection for time series data with generative adversarial networks[C]//Proceedings of the 28th International Conference on Artificial Neural Networks and Machine Learning. Munich: Springer, 2019. DOI: 10.1007/978-3-030-30490-4_56
- [16] DU Xiaolong, BAI Meng. Anomaly detection method for satellite telemetry parameters based on time-series imputation generative adversarial networks[J]. *Chinese Journal of Space Science*, 2025, **45**(4):1087-1097 (杜晓龙, 白萌. 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[J]. *空间科学学报*, 2025, **45**(4):1087-1097)
- [17] CESPEDES A J J, PANGESTU B H B, HANAZAWA A, *et al.* Performance evaluation of machine learning methods for anomaly detection in CubeSat solar panels[J]. *Applied Sciences*, 2022, **12**(17): 8634. DOI: 10.3390/app12178634
- [18] PENG Xiyuan, PANG Jingyue, PENG Yu, *et al.* Review on anomaly detection of spacecraft telemetry data[J]. *Chinese Journal of Scientific Instrument*, 2016, **37**(9):1929-1945. DOI: 10.3969/j.issn.0254-3087.2016.09.003 (彭喜元, 庞景月, 彭宇, 等. 航天器遥测数据异常检测综述 [J]. *仪器仪表学报*, 2016, **37**(9): 1929-1945. DOI: 10.3969/j.issn.0254-3087.2016.09.003)

王业昕 女, 2001 年 4 月出生于山东潍坊, 现为中国科学院国家空间科学中心在读硕士研究生, 主要研究方向为空间大数据处理与应用技术、卫星智能运控技术等。

Email:wangeyxin23@mailsucas.ac.cn.



肖志刚 男, 1976 年 9 月出生于河南周口, 中国科学院国家空间科学中心副研究员, 硕士生导师, 主要研究方向为卫星智能运控技术、大数据处理分析技术和卫星载荷健康管理技术等. Email:xiaozhigang@nssc.ac.cn

