

基于时频特征分析与对抗训练的卫星遥测 参数异常检测方法

平凡^{1,2} 苏举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 卫星遥测数据直接反映卫星在轨运行状态，检测其中的异常对保障卫星安全稳定具有重要意义。针对现有方法在捕捉复杂异常模式方面的不足，本文提出一种基于时频特征分析与对抗训练的异常检测方法。方法引入频域注意力机制，有效捕获频域中的周期性模式和微弱异常特征，并通过时频域协同分析建立时域与频域特征之间的关联，以全面感知复杂异常模式。在简化 Transformer 架构基础上，结合对抗训练策略提升模型对异常的判别能力。在多个公开基准数据集及科学卫星热控系统遥测数据集上的对比实验与消融实验结果表明，所提方法在卫星遥测数据异常检测任务中表现优异，可为卫星在轨安全运行提供有效技术支撑。

关键词 卫星遥测数据，异常检测，Transformer，对抗训练，时频特征
中图分类号 V474

Anomaly Detection for Satellite Telemetry Parameters Based on Time-Frequency Feature Analysis and Adversarial Training

PING Fan^{1,2} SU Ju¹

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

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

Abstract Satellite telemetry data directly reflects the operational status of in-orbit satellites, and detecting anomalies from such data is of great importance for ensuring satellite safety and stability. Existing anomaly detection methods often face limitations in capturing complex anomaly patterns, especially those involving periodic behaviors that are common in satellite telemetry. To address this issue, this paper proposes a novel anomaly detection approach based on time-frequency feature analysis and adversarial training. Specifically, a frequency-domain attention mechanism is introduced to effectively capture

* 基金项目：科学卫星任务运控与决策支持技术（GJ11050203）

投稿日期：2026 年 1 月 4 日

E-mail: pingfan23@mailsucas.ac.cn

periodic patterns and subtle anomalous features in the frequency spectrum. Unlike conventional methods that treat time and frequency separately, our approach further includes a time-frequency collaborative analysis module designed to establish correlations between time-domain and frequency-domain features, thereby enabling a comprehensive perception of complex anomaly patterns, with particular emphasis on periodic anomalies. On the basis of a simplified Transformer architecture, an adversarial training strategy is incorporated to enhance the model's discriminative ability for anomalies. In this framework, two decoders with opposite learning directions are employed: one aims to reconstruct normal patterns while the other competes by learning to identify deviations, together forcing the model to learn more robust and generalizable feature representations. Extensive experiments are conducted on multiple public benchmark datasets as well as a real-world telemetry dataset collected from the thermal control system of a scientific satellite. Both comparative experiments and ablation studies are carried out to evaluate the proposed method.

The comparative results demonstrate that the proposed method achieves strong and competitive performance in satellite telemetry anomaly detection tasks. Meanwhile, the ablation studies verify the individual contributions of the frequency-domain attention mechanism and the adversarial training component, confirming that each module plays a meaningful role in improving detection accuracy. In summary, this work provides effective technical support for the safe in-orbit operation of satellites and offers a promising direction for time-series anomaly detection in similar aerospace systems.

Key words satellite telemetry data, anomaly detection, Transformer, adversarial training, time-frequency feature.

0 引言

随着我国科技水平的不断提高,空间科学技术得到了快速发展,卫星作为空间科学的重要工具,扮演着重要的角色^[1]。其运行状态的监控与维护显得尤为重要。卫星遥测数据是卫星在轨运行过程中产生的重要数据,全面反映了卫星的运行状态,检测其中异常对维护卫星的安全与稳定具有重要意义。

时间序列异常检测方法大致可分为传统机器学习方法和深度学习方法两大类。传统机器学习方法主要基于统计模型和机器学习算法,如 Z-Score 分析、支持向量机 (SVM)^[2]、密度估计 LOF^[3]和聚类方法 SVDD^[4]等。这些方法通过构造决策边界、估计局部密度或构建紧凑聚类来识别异常模式,为异常检测奠定了重要基础。然而,这些方法在处理复杂、周期性、多变量等时序异常存在局限性,因此,采用基于深度学习的学习型方法变得至关重要。

近年来,深度学习方法在时间序列异常检测中展现出显著优势,主要分为基于预测和基于重构的两类方法。基于预测的方法通过 LSTM、CNN 或 Transformer^[5]等序列到序列模型估计未来值,利用预测偏差作为异常分数;基于重构的方法则采用自编码器架构,通过重构

误差检测异常。基于重构的方法通过编码器-解码器架构学习数据分布，利用重构误差差异建立异常判别边界。代表性方法包括 DAGMM^[6]、VAE^[7]、LSTM-VAE^[8]、AnomalyTransformer^[9]等，以及采用对抗训练的 TranAD^[10]、MAD^[11]和 USAD^[12]等方法。结合频域信息的异常检测方法，能够有效提升卫星遥测数据中多种异常的识别准确率^[13]，FEDformer^[14]以 FFT 将自注意力映射到频域，并通过季节趋势特征分解实现长期序列预测。

尽管现有方法取得一定成功，但在卫星遥测领域仍面临特殊挑战。由于卫星运动的周期性，其相关传感器数据具有明显的周期性工作模式，对其数据的分析建模仍面临着以下问题：首先，重构方法的重构误差在不同周期状态下波动较大，阈值难以统一确定；其次，现有深度学习方法对时序数据进行建模时较少考虑频域特征^[15]，导致可能仅在特定场景下表现良好，难以全面捕获卫星遥测数据中的复杂异常模式。

针对上述问题，本文构建一种面向卫星遥测周期工况的重构异常检测框架。现有方法多将频域信息作为辅助特征输入模型，侧重于特征维度的扩充，未显式利用频域周期信息指导重构过程。为此，方法在编码阶段引入频域注意力机制，使频域周期信息参与重构目标；在表示学习阶段联合建模时域趋势与频域周期信息，通过跨域耦合刻画两者的协同变化；在优化阶段采用双解码器对抗式重构训练，使模型对正常模式形成更紧致重构分布，并在异常扰动下产生更具区分性的误差响应。

1 卫星遥测数据异常检测

1.1 卫星遥测数据特征

卫星在轨运行期间，相关传感器会产生大量的遥测数据，通过对遥测数据进行异常检测分析，是保障卫星平稳运行的有效手段^[16]。卫星遥测数据典型的多维度、时变性和季节性周期特征，这些季节性模式主要源于卫星绕地球运行的周期性轨道特性、太阳照射角度的周期性变化以及卫星本身的周期性调节行为。传统的方法难以适应这种复杂的季节性特征，在处理具有季节性模式的时序异常时存在显著局限性^[17]。

基于异常在周期性时间序列遥测数据中表现出的形态变化模式，可划分为趋势异常、周期性异常与波形异常三类^[18]。趋势异常指遥测数据的长期趋势发生显著变化，如阶跃型异常或梯度型异常，常见于温度或电压数据中，可能暗示系统级故障如热失控或电压跌落。周期性异常指遥测数据的周期发生改变，即使其数值仍在正常范围内。例如，依赖卫星轨道周期的电池电压或表面温度数据若出现周期偏移，常指示系统时序或任务模式异常。波形异常指遥测信号的波形形态或振幅发生异常变化，可能由设备性能退化或部件故障引起，表现为信号失真、畸变或幅度异常。

卫星遥测数据中的三种典型异常类型在时域或频域有不同的表现特征。趋势异常在时域表现为长期趋势变化；周期性异常在频域可直接检测周期偏移和频率变化；波形异常的形态畸变和谐波失真可分别在时域和频域捕获。这种协同分析能够全面感知复杂异常模式。

1.2 重构方法

基于重构的深度学习方法通过编码器-解码器架构学习时间序列的正常模式，利用正常数据重构误差小而异常数据重构误差大的特性进行异常检测。图 1 所示，该方法将连续时间序列分割为固定长度的窗口片段，通过编码器压缩为潜在特征后再由解码器重构，通过比较重构结果与原始输入的差异来识别异常，能够有效检测点异常和持续性异常子序列。




图 1 重构方法检测

Fig. 1 Anomaly detection based on reconstruction

1.3 时频域分析方法

时频域分析是信号处理领域的重要技术，能够同时揭示信号在时域和频域的特征信息。传统时间序列分析主要关注时域特征，如趋势、均值、方差等，忽略了频域中蕴含的丰富周期性信息。频域分析通过傅立叶变换将时域信号转换到频域，可以识别信号中的周期性模式、频率成分变化以及频谱能量分布等关键特征。

时频域分析方法通过融合时域的瞬态特征和频域的周期特征，为时间序列异常检测提供了更加全面的特征表示。这种方法不仅能够捕获传统时域分析容易遗漏的频谱异常，还能通过频域信息增强对复杂异常模式的识别能力。随着深度学习技术与信号处理理论的不融合，时频域分析方法在时间序列异常检测领域展现出巨大的应用潜力。

2 异常检测方法

2.1 模型架构

模型以简化的 Transformer 架构为主体，在编码过程中引入频域注意力以强化周期模式约束，在表示学习过程中联合刻画时域趋势与频域周期信息，并在重构优化过程中采用双解码器对抗训练提升异常判别稳定性。




图 2 模型架构

Fig. 2 Model architecture

图 2 展示了模型的整体架构设计。模型采用编码器-解码器架构，整体流程遵循对抗训练的两阶段重建策略。在数据输入阶段，模型接收时间序列数据，通过数据嵌入层将原始特征映射到隐藏空间，该嵌入层同时集成了位置编码信息以保持序列的时序特性。

在编码阶段，序列表示首先经频域注意力机制（SpectralMHA）建模时间步依赖并强化

周期相关信息，随后通过时频特征提取过程（Series Decomposition）分解并刻画季节性与趋势性成分，最终在季节趋势融合后形成编码器输出特征。

在解码器处理阶段，除图中基本流程外，模型采用两阶段重建机制。第一阶段解码器使用零矩阵作为条件输入，通过交叉注意力机制（MHA）初产生第一个重建结果。第二阶段解码器则利用第一阶段的重建误差作为条件输入，通过交叉注意力产生第二个重建结果。这种两阶段设计使得模型能够先进行无偏重建，再利用重建误差指导精细化重建，从而提高异常检测的准确性。

模型的前向传播过程协调这两个阶段的工作，首先通过编码器处理输入数据，然后依次执行两个解码阶段，最终输出两个重建结果。在训练过程中，模型采用动态加权损失函数，随着训练轮次的增加逐渐增加对抗损失的权重。在推理阶段，模型仅使用解码器 2 重建误差作为异常评分，因为该阶段的输出包含了异常感知信息，对异常点更加敏感。

2.2 频域注意力

频域注意力机制通过引入频域分析来增强对周期性异常的捕捉能力。传统注意力机制主要关注时域依赖关系，忽略了频域中的周期信息。频域注意力通过 FFT 将信号转换到频域，利用可学习的频率权重增强关键频率成分，再通过 IFFT 转换回时域，实现时频信息的有效融合。该机制基于异常在频域中表现为频谱能量分布变化的假设，能够有效捕获时域微弱的频域异常模式。

频域分解：首先对输入序列进行快速傅里叶变换，将时域信号转换到频域：

$$X_{\text{freq}} = \text{FFT}(X) \quad (1)$$

其中 X 表示原始时域输入序列，形状为 $B \times L \times D$ ， B 为批量大小（batch size）， L 为序列长度（sequence length）， D 为特征维度（feature dimension）。考虑到输入为实值序列，采用单边频谱的 rFFT/irFFT 进行频域变换，频率维 X_{freq} 长度为 $L_f = \lfloor L/2 \rfloor + 1$ ；为保持符号简洁，下文仍以 FFT/IFFT 统称该过程。

为增强关键频率成分，引入可学习的频率权重 $\omega \in \mathbb{R}^K$ ， $K = L_f$ 表示频率维的频点数；学习未归一化的频率打分 $\omega_0 \in \mathbb{R}^K$ ，令 $\omega = \text{softmax}(\omega_0)$ 得到频率权重分布。

$$\tilde{X}_{\text{freq}} = X_{\text{freq}} \odot (1 + \omega) \quad (2)$$

其中 $\odot$ 表示逐元素相乘，从而实现对 X_{freq} 的逐频点加权。

将调整后的频域特征通过逆傅里叶变换转换回时域：

$$X_{\text{enhanced}} = \text{IFFT}(\tilde{X}_{\text{freq}}) \in \mathbb{R}^{B \times L \times D} \quad (3)$$

其中 $\tilde{X}_{\text{freq}}$ 表示经频率加权后的频域表示，将频谱还原为长度为 L 的实值时域序列。

时频特征融合：将增强后的频域特征 X_{enhanced} 与原始时域特征 X 拼接，通过 MLP 融合后添加残差连接：

$$X_{\text{final}} = \text{MLP}([X; X_{\text{enhanced}}]) + X \quad (4)$$

其中 $[\cdot; \cdot]$ 表示特征拼接。

在频域注意力模块中，采用自注意力对融合后的序列进行依赖建模。具体地，由前文得到的融合序列 X_{final} 通过三组线性映射分别生成查询 Q 、键 K 和值 V ：

$$Q = X_{\text{final}} W_Q, \quad K = X_{\text{final}} W_K, \quad V = X_{\text{final}} W_V \quad (5)$$

其中 W_Q, W_K, W_V 为可学习参数矩阵。随后计算自注意力输出：

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (6)$$

其中， Q, K, V 由式(5)给出， d_k 为键向量维度； $\sqrt{d_k}$ 用于缩放点积以稳定训练， Softmax 用于将注意力分数归一化为概率分布，得到频域注意力模块的最终输出。

2.3 时频特征提取

时间序列异常通常表现为时域特征（如趋势突变、均值漂移）和频域特征（如周期性变化、频谱异常）的复合模式。为全面捕获这些异常特征，本节提出一种时频域协同分析框架，分别处理时域趋势特征和频域周期特征，并通过特征融合实现异常检测性能的提升。

图 3 展示了时频域特征提取的完整流程。原始时间序列信号通过时域分析提取趋势分量，通过频域分析提取周期分量，最终融合形成综合特征用于异常检测。这种特征提取策略使得异常检测更加精准，因为不同类型的异常会在不同的域中表现出特征性变化。




图 3 时频域特征提取

Fig. 3 time-frequency feature extraction

2.3.1 趋势成分提取

时域趋势分析旨在提取时间序列的长期演化模式和短期变化特征。给定输入时间序列 $x=[x_1, x_2, \dots, x_T] \in \mathbb{R}^T$ ，本节提出多尺度加权趋势提取方法，通过自适应权重学习机制融合不同时间尺度的趋势特征。

多尺度趋势建模。对于第 i 个趋势尺度，定义趋势提取函数为：

$$\text{Trend}^{(i)}(x) = \text{MA}_{k_i}(x) = [\text{MA}_{k_i,1}(x), \text{MA}_{k_i,2}(x), \dots, \text{MA}_{k_i,T}(x)] \quad (7)$$

其中 $\text{MA}_{k_i,t}(x)$ 表示在时刻 t 处窗口大小为 k_i 的对称移动平均：

$$\text{MA}_{k_i,t}(x) = \frac{1}{k_i} \sum_{j=-(k_i-1)/2}^{(k_i-1)/2} x_{t+j} \quad (8)$$

为保证移动平均在边界处仍定义良好并保持输出长度为 T ，对序列进行端点延拓，用 x_1 与 x_T 进行填充，再以步长为 1 计算长度为 k_i 的滑动平均。对称移动平均设计有效消除了传统移动平均的边缘效应问题，保证了趋势估计的准确性。




图 4 多尺度趋势特征提取

Fig. 4 Multi-scale trend extraction.

图 4 展示了多尺度趋势提取的可视化结果。(a)为原始的输入时序数据，(b)为移动窗口 1 的趋势提取结果，(c)为移动窗口 2 的趋势提取结果，(d)为移动窗口 3 的提取结果。通过对比不同窗口大小下的趋势提取效果，可以观察到窗口尺寸对趋势平滑程度的影响：较小的窗口能够保留更多的细节波动，而较大的窗口则能更好地捕捉长期趋势。

最终的趋势特征通过加权融合获得：

$$\text{Trend}(x) = \sum_{i=1}^n w_i \cdot \text{Trend}^{(i)}(x) \quad (9)$$

权重 w 由可学习的线性映射后经 softmax 归一化得到。核大小分别取 $\{4, 8, 12\}$ ，核数量为 3、步长为 1。

理论分析表明，当输入序列存在趋势异常时，不同尺度的趋势分量会产生显著差异，通过学习得到的权重分布能够自动突出异常相关的尺度特征。

2.3.2 周期成分提取

通过快速傅立叶变换(FFT)将时域信号转换到频域，从而识别时间序列中隐藏的周期性模式和频谱异常。本节提出基于频率选择的周期特征提取方法。

傅立叶变换。对输入时间序列 x 应用离散傅立叶变换：

$$X = \text{FFT}(x) = [X_0, X_1, \dots, X_{T-1}] \quad (10)$$

其中 $X_k = \sum_{t=0}^{T-1} x_t \cdot e^{-j2\pi kt/T}$ 表示第 k 个频率分量的复数振幅。

Top-K 频率选择。为提取主要周期，在正频率范围内计算频点能量并排序，仅保留能量最大的 K 个频点索引。对多变量序列 $x_t \in \mathbb{R}^D$ ，令 $X_{k,d}$ 表示第 d 个变量在第 k 个频点的复数系数，定义频点能量 E_k 为：

$$E_k = \frac{1}{D} \sum_{d=1}^D |X_{k,d}|^2, k=1, \dots, [T/2] \quad K = \text{TopK}(\mathbf{E}) = \{k \mid E_k \text{ 位于 } \mathbf{E} \text{ 的前 } K \text{ 大}\} \quad (11)$$

其中 $|X_{k,d}|^2$ 为复数系数 $X_{k,d}$ 的模平方，用于度量该频点在第 d 个变量上的能量贡献。 $k=0$ 对应均值项不参与排序， $\mathbf{E} = [E_1, \dots, E_{[T/2]}]$ 对每个长度为 T 的输入窗口独立执行上述排序与截断得到 K ，其中 K 为保留频点个数的超参数，实验设置取 $K=3$ 。

周期特征重构。通过逆傅立叶变换将筛选后的频谱分量重构为时域周期特征：

$$\text{Season}(x) = \text{IFFT}(\tilde{X}) \quad (12)$$

其中重构频谱 $\tilde{X}$ 为: $\tilde{X} = X_k, k \in K$

图 5 展示了周期特征提取, (a)图为原始时间序列, (b)图为通过周期特征提取的特征序列。频域周期分析能够有效识别时间序列中的周期性异常, 如周期模式的突然变化、新频率成分的出现等。




图 5 周期特征提取

Fig. 5 Seasonal feature extraction

2.4 对抗网络训练

为解决训练的稳定性问题(对抗性训练框架常见), 使用两阶段融合训练方法。与传统的严格两阶段训练不同, 采用统一的损失函数, 通过动态权重调整机制实现训练重点的平滑过渡, 同时保持对抗训练的核心思想。

阶段 1: 重建训练。输入数据 x 由编码器压缩到潜在空间 z , 然后由每个解码器重建。解码器 1 的重构误差 $(O_1 - x)^2$ 通过投影生成聚焦特征 F , 在解码器 2 中, F 与编码器输出 z 进行交叉注意力, 以突出误差相关区域并提升重构判别性。训练损失函数:

$$L_{\text{recon1}} = \|x - \text{Decoder}_1(z)\|_2, \quad L_{\text{recon2}} = \|x - \text{Decoder}_2(z, F)\|_2 \quad (13)$$

其中 $x \in \mathbb{R}^{T \times D}$ 表示长度为 T 的输入窗口, D 为数据维度, $z = \text{Encoder}(x)$ 为编码器输出; 采用 MSE 对上述重构误差进行度量。

阶段 2: 对抗重构。在第一阶段得到 $O_1 = \text{Decoder}_1(z)$ 后, 将 O_1 重新送入编码器, 再由解码器 2 进行二次重构。该过程可写为

$$O_2^{\text{adv}} = \text{Decoder}_2(\text{Encoder}(O_1)) \quad (14)$$

通过该由重构、再编码与二次重构构成的映射链路, 模型显式度量第一阶段输出在第二阶段中的可重构性, 并以统一误差项构造对抗目标。对抗训练目标:

$$\min_{\text{Decoder}_1} \max_{\text{Decoder}_2} \|x - \text{Decoder}_2(\text{Encoder}(\text{Decoder}_1(z)))\|_2 \quad (15)$$

定义共享对抗误差

$$E_{\text{adv}} = \|x - \text{Decoder}_2(\text{Encoder}(\text{Decoder}_1(z)))\|_2 \quad (16)$$

其中 $\min / \max$ 分别表示两个解码器对同一误差项执行相反优化方向, 由于 $E_{\text{adv}} \geq 0$, Decoder2 最小化 $L_{\text{adv2}} = -E_{\text{adv}}$ 等价于最大化 E_{adv} , 从而与 Decoder1 在同一误差项上形成相反优化方向。

对抗损失函数:

$$L_{adv1}=E_{adv} \quad L_{adv2}=-E_{adv} \quad (17)$$

其中 L_{adv1} 与 L_{adv2} 由同一对抗误差项构成，仅符号相反，用于表示两个解码器在对抗博弈中的相反优化方向，Decoder1 最小化 E_{adv} 以使 O1 易于被 Decoder2 二次重构；Decoder2 最大化 E_{adv} 以放大 Decoder1 重建中的误差。二者对 E_{adv} 优化方向相反，构成 Decoder1“欺骗”、Decoder2“揭露”的对抗博弈。

动态加权损失函数。采用动态加权损失机制来实现两阶段训练的平滑过渡。该机制通过线性权重调整，在训练初期重点关注重构能力培养，随着训练进行逐渐增加对抗训练的重要性。具体而言，两个解码器使用不同的损失函数进行训练：

$$L_{dec1}=\frac{1}{n} \cdot L_{recon1}+\left(1-\frac{1}{n}\right) \cdot L_{adv1} \quad (18)$$

$$L_{dec2}=\frac{1}{n} \cdot L_{recon2}+\left(1-\frac{1}{n}\right) \cdot L_{adv2} \quad (19)$$

其中 $n=epoch$ 为当前训练轮次数（从 1 开始计数）， L_{recon1} 和 L_{recon2} 分别为两个解码器的重构损失， L_{adv1} 和 L_{adv2} 分别为两个解码器的对抗损失。解码器 1 最小化对抗损失而解码器 2 最大化对抗损失，形成对抗训练机制。

这种权重调整策略确保了训练稳定性：在训练初期（epoch 较小时）， $1/n$ 较大，模型优先学习基础重构能力；随着重建质量提升， $1-1/n$ 逐渐增大，对抗训练得到更多关注，使模型能够更好地捕获异常模式。

2.5 异常检测阈值选择方法

异常检测模型输出的重构误差可作为异常分数（数值越大越异常）。在告警判定时，需要设定阈值 θ 将连续分数二值化：当 $s>\theta$ 时判为异常。由于阈值会显著影响 $PC/RC/F1$ 等评价指标，本文对阈值确定过程作如下说明。

（1）离线对比评测：Best-F1 阈值。在公开基准数据集的离线对比中，为减少“阈值策略差异”对不同方法结果的影响，本文采用 Best-F1 作为统一报告口径：在候选阈值集合 $R=\{r_1, r_2, \dots, r_{100}\}$ 上进行网格搜索，选取使 F1 最大的阈值

$$\theta^*=\arg \max _{\theta \in R} F1\left(\hat{L}_{\theta}, L\right) \quad (20)$$

其中 $\hat{L}_{\theta}$ 为阈值 θ 下的预测标签， L 为真实标签。Best-F1 依赖已知标签，属于后验最优阈值，实际在线遥测场景中通常无法获得同等条件的标签信息，因此实际部署不应采用 Best-F1；本文使用 Best-F1 的目的仅为减少“阈值策略差异”对不同方法结果的影响。

（2）实际应用：基于正常数据与虚警约束的阈值。在工程场景中，阈值通常基于一段正常的历史数据确定。记正常校准集为 D_{norm} ，对应异常分数集合 $\{s_i\}$ ，常用做法为：给定允许的虚警率 α ，取分位数阈值

$$\theta_{\alpha}=Q_{1-\alpha}\left(\left\{s_i\right\}_{i \in D_{norm}}\right) \quad (21)$$

其中 $Q_p(\cdot)$ 表示 p 分位数。该方法不依赖异常标签，且可直接将业务约束的虚警水平映射为阈值设定。

3 实验

3.1 异常重建




图 6 异常重建

Fig. 6 Anomaly reconstruction.

图 6 可视化了时序数据上的重建结果，包括趋势异常重建，季节性异常重建，和波形异常重建。模型在训练阶段学习到正常遥测数据的时序依赖与模式关联，当输入包含异常数据时，破坏了学习到的正常特征关系，导致模型无法准确重建异常片段。可以看到正常数据段的重建结果与原始信号高度重合，重建误差极小；而异常数据段的重建结果与原始信号偏差明显，重建误差显著增大，能够直接区分正常与异常序列。

3.2 模型训练




图 7 模型训练损失

Fig. 7 Model training loss

图 7 展示了模型训练过程中两个解码器的损失的变化趋势，显示出模型在训练的 10 个 epoch 中逐渐收敛，损失值稳步下降，验证了模型的对抗训练策略稳定性和有效性。其中解码器 2 的损失值线高于解码器 1 后又随着训练的进行又逐步低于解码器 1，这说明在训练初始阶段由于解码器 1 还不能很好的重建输入数据，对抗训练策略又要求解码器 1 的数据要重新送回解码器 2 进行对抗学习，使得初始阶段解码器 2 的初始损失较大，但随着训练的进行，对抗训练策略和聚焦损失机制又帮助了解码器 2 更好的重建输入的数据。

3.3 注意力权重可视化




图 8 注意力权重分布可视化

Fig. 8 Attention weight distribution visualization.

图 8 展示了两种不同的注意力机制学习到的注意力权重的可视化图，(a)为原始注意力权重，(b)为频域注意力权重。可以看到原始的多头注意力权重分布较为分散，而频域注意力权重分布则更加集中，具体体现在图 8 中(a)图高亮点较少，而(b)图高亮点较多，这说明频域注意力机制能够有效提取时间序列的频域特征，使注意力集中在特定区域，增强异常检测的准确性。

3.4 复杂度与实时性分析

本文提出的模型简称为 TFAT (Time-Frequency Adversarial Transformer)。从理论分析角度，设批量大小为 B 、序列长度为 L 、特征维度为 D 。Transformer 类模型的主导开销来自注意力计算，其单层前向时间复杂度可近似表示为 $O(BL^2D)$ 。在此基础上，TFAT 引入的 FFT/IFFT 与时频分解主要增加约 $O(BDL \log L)$ 的额外计算量，双解码器结构使解码端计算开销近似增加一个常数倍。总体而言，方法的渐近量级与基线 Transformer 保持一致，额外代价主要体现在常数项与 $L \log L$ 项。




图 9 不同批大小下模型迭代速度对比

Fig. 9 Comparison of model iterations per second under different batch sizes

为评估在线推理吞吐，统计在 RTX 4090 的硬件条件下，序列长度 L 取 100 时在不同批大小下的每秒迭代次数 (Iterations Per Second, IPS)，结果如图 9 所示。在线处理能力按 batch size 为 1 的单样本流式推理口径统计，当 batch size 为 1 时，Transformer 基线的平均 IPS 为 62 次/秒，TFAT 的平均 IPS 约为 35 次/秒，对应每秒可处理最大采样点数约为 6200 与 3500。尽管引入频域建模与双解码器带来额外开销，TFAT 仍可满足一般遥测场景的在线检测需求。

3.5 对比实验及结果

为了全面评估模型的性能,选取了基于高斯混合模型的 DAGMM^[6],基于变分自编码器的 LSTM-VAE^[8],基于卷积自编码器的 CAE-M^[18],基于图的 MSHTrans^[20]、MTAD-GAT^[21],基于对抗网络的 MAD-GAN^[11]、USAD^[12]、TranAD^[10],以及引入了重建趋势增强 Transformer 的 RTDetector^[22]和融合时域与频域分析的 TFAD^[23]。选取的数据集包括三个公开的基准数据集如表 1 所示。

表 1 数据集信息

Table 1 Datasets information

数据集	来源	数据维度	数据类型	训练集/测试集长度
SWaT	水处理系统	51	连续型为主 含少量离散型变量	495000/449918
MSL	火星科学实验室	55	连续型为主 含少量离散型变量	58317/73729
SMD	服务器机器数据集	38	连续型为主 含少量离散型变量	561192/561203
KXRK	科学卫星热控系统	34	连续型	10080/5100

其中 MSL 和 SMD 数据集当中包含多个实体,结果取各个实体结果的平均值,因此在 MSL 和 SMD 的数据集上的 F1 分数与标准的计算公式并不对应。对于自建的科学卫星热控系统遥测数据集 KXRK,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。这些数据集代表了不同领域的时间序列异常检测场景,从公开的基础设施监控系统到科学卫星热控系统。

3.5.1 评价指标说明

研究采用异常检测领域内广泛认可的评价指标,包括精确率 (Precision PC)、召回率 (Recall RC) 以及 F1 分数^{[22][24]}。对比试验采用了四个广泛使用的评价指标: 精确率表示被模型预测为异常的样本中,真正异常的比例。召回率表示所有真实异常样本中,被模型正确识别出来的比例。F1 分数是精确率和召回率的调和平均数,计算公式为 $F1=2 \times (PC \times RC) / (PC + RC)$ 。F1 分数综合考虑了模型的精确率和召回率,是异常检测任务的主要评价指标。

3.5.2 整体性能分析

表 2 给出了所提出模型与多种代表性异常检测方法在 SWaT,MSL,SMD 和 KXRK 四个数据集上的性能对比结果。为便于比较,表中各数据集的 F1 列对排名前两位的方法结果进行了加粗标注。从整体结果可以看出,所提出模型在 SWaT,MSL 和 KXRK 数据集上均取得了最高的 F1 分数,在工业控制系统数据和真实卫星遥测数据场景下均表现出较强的异常检测能力。

在 SMD 数据集上,模型的 F1 分数虽未达到最优,但仍保持在同类方法中的较高水平,表现出较好的竞争力。分析认为,这与上述数据集中异常模式具有更强的离散性特征有关,在该类场景下,模型的时频协同分析机制在部分离散数据异常模式上的建模仍存在一定挑战。

进一步从跨数据集汇总指标看,所提出模型在四个数据集上的平均 F1 分数为 0.629,

高于对比方法。该结果说明，在数据分布与异常类型存在差异的条件下，模型仍能保持较稳定的综合检测水平，体现出较好的跨场景适应性与鲁棒性。

表 2 不同模型在四个数据集上的性能对比

Table 2 Performance comparison of different models on four datasets

模型	SWaT			MSL			SMD			KXRK			平均
	F1	PC	RC	F1	PC	RC	F1	PC	RC	F1	PC	RC	
DAGMM	0.730	0.990	0.578	0.371	0.394	0.723	0.371	0.441	0.599	0.674	0.943	0.525	0.537
LSTM-VAE	0.734	0.996	0.581	0.369	0.372	0.488	0.429	0.460	0.514	0.869	0.956	0.796	0.600
CAE-M	0.675	0.854	0.563	0.365	0.322	0.418	0.394	0.474	0.535	0.758	0.965	0.624	0.548
MSHTrans	0.754	0.967	0.644	0.348	0.309	0.674	0.419	0.468	0.475	0.874	0.961	0.800	0.599
MAD-GAN	0.739	0.924	0.616	0.362	0.326	0.634	0.350	0.455	0.574	0.851	0.999	0.742	0.576
MTAD-GAT	0.771	0.964	0.642	0.372	0.357	0.598	0.408	0.465	0.510	0.439	0.351	0.583	0.497
USAD	0.764	0.956	0.637	0.327	0.269	0.603	0.444	0.516	0.549	0.879	0.836	0.928	0.603
RTdetector	0.765	0.957	0.637	0.335	0.325	0.606	0.426	0.404	0.497	0.752	0.958	0.617	0.570
TFAD	0.790	0.921	0.690	0.364	0.343	0.640	0.434	0.441	0.586	0.874	0.829	0.921	0.616
TranAD	0.802	0.940	0.701	0.367	0.359	0.638	0.425	0.488	0.558	0.881	0.951	0.819	0.619
TFAT	0.816	0.897	0.747	0.374	0.344	0.651	0.440	0.473	0.537	0.889	0.926	0.855	0.629

3.6 消融实验

为了验证模型中各个组件的有效性，设计进行了系统的消融实验。分别移除了模型中的三个核心组件：对抗训练机制、频域注意力和时频域特征提取模块，并在三个基准数据集和一个科学卫星遥测数据集上进行了对比实验。




图 10 模型消融实验结果对比

Fig. 10 Performance comparison of model ablation experiments

图 10 的消融实验结果表明，模型中的每个组件都对整体性能有重要贡献，但其贡献程度因数据集特性而异。时频特征提取模块在 SWaT 和 SMD 数据集上都表现出稳定的正面贡献。对抗训练机制的贡献则更具数据集特异性，在如 SWaT 上表现突出。消融的对比分析显示，频域注意力模块与时频域特征提取模块这两个频域相关组件对性能的贡献存在差异，其中时频域特征提取的影响更为显著。这些组件的协同作用使得模型能够在复杂的时间序列异

常检测任务中取得优异的性能,其中频域注意力提供了基础的特征提取能力,对抗训练机制和解码器进一步增强了对复杂异常模式的识别能力,而频域特征提取模块则提供了额外的频率特征补充。

4 结论

针对卫星遥测数据异常检测中时频信息利用不充分的问题,本文提出了基于时频特征分析与对抗训练的异常检测方法。该方法通过频域注意力与时频协同特征提取增强周期模式建模能力,并结合双解码器对抗训练提升对异常重建误差的判别能力。综合对比表明,本文方法在多个数据集上取得了具有竞争力的检测性能,总体 F1 结果处于较优水平,体现出该方法在时序异常检测任务中的有效性。

同时,实验结果也表明该方法的性能优势具有一定数据依赖性,在部分包含离散型数据的数据场景中,模型性能稳定性仍有提升空间。因此,本文方法更适用于具有周期性与趋势性特征的连续型数据的异常检测任务。本文提出的方法在具有周期性与趋势性特征的卫星遥测场景中,可为卫星运控人员提供决策参考;通过识别遥测数据中的异常模式,有助于运控人员及时发现潜在系统故障并采取相应处置措施,从而保障卫星在轨运行的安全性与可靠性。

参考文献

- [1] 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)
- [2] HEARST MA, DUMAIS S T, OSUNA E, *et al.* Support vector machines[J]. *IEEE Intelligent Systems and their applications*, 1998, **13**(4): 18-28
- [3] BREUNIG M M, KRIEGER H P, NG R T, *et al.* LOF: identifying density-based local outliers[J]. *ACM SIGMOD Conference*, 2000, **29**(2): 93-104
- [4] TAX D M J, DUIN R P W. Support vector data description[J]. *Machine Learning*, 2004, **54**(1): 45-66
- [5] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2017
- [6] ZONG B, SONG Q, MIN M R, *et al.* Deep autoencoding Gaussian mixture model for unsupervised anomaly detection[C]//6th International Conference on Learning Representations. Canada: Vancouver, 2018
- [7] KINGMA D P, WELING M. Auto-encoding variational Bayes[OL]. arXiv preprint arXiv: 1312. 6114, 2013
- [8] PARK D, HOSHI Y, KEMPC 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
- [9] XU J H, WU H X, WANG J M, *et al.* Anomaly transformer: Time series anomaly detection with association discrepancy[OL]. arXiv preprint arXiv: 2110. 02642, 2021
- [10] TULI S, CASALE G, JENNINGS N R. TranAD: deep transformer networks for anomaly detection in multivariate time series data[OL]. arXiv preprint arXiv: 2201. 07284, 2022
- [11] LI D, CHEN D C, JIN B H, *et al.* MAD-GAN: multivariate anomaly detection for time series data with generative adversarial networks[C]//28th International Conference on Artificial Neural Networks. Cham: Springer, 2019: 703-716
- [12] AUDIBERT J, MICHIARDI P, GUYARD F, *et al.* USAD: UnSupervised anomaly detection on multivariate time series[C]//

-
- Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2020: 3395-3404
- [13] LI Chao, WANG Linlin. A satellite anomaly detection algorithm based on time-frequency domain reconstruction error[J/OL]. Journal of University of Chinese Academy of Sciences, 2025. <http://journalucas.ac.cn/CN/10.7523/jucas.2025.047> (李超, 王林林. 一种基于时频域重构误差的卫星遥测数据异常检测算法[J/OL]. 中国科学院大学学报, 2025. <http://journalucas.ac.cn/CN/10.7523/jucas.2025.047>)
- [14] 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
- [15] WU P Q, LIU J W, HAN J Y. SFMixer: Local periodic features in frequency domain and global features in time domain modeling for long-term time series forecasting[C]//2024 China Automation Congress (CAC). Qingdao: IEEE, 2024: 2059-2064
- [16] YANG Jiasen. Research on Correlation Knowledge Discovery Method of Spacecraft Telemetry Data[D]. Beijing: University of Chinese Academy of Sciences(National Space Science Center, 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)
- [17] DARBAN Z Z, WEBB G I, PAN S R, *et al.* Deep learning for time series anomaly detection: a survey[J]. *ACM Computing Surveys*, 2024, **57**(1): 1-42.
- [18] KATSUBE S, SAHARA H. Telemetry monitoring system with features explaining anomalies based on mahalanobis distance[J]. *International Journal of Prognostics and Health Management*, 2024, **15**(2).DOI: 10.36001/ijphm.2024.v15i2.3945
- [19] ZHANG Y X, CHEN Y Q, WANG J D, *et al.* Unsupervised deep anomaly detection for multi-sensor time-series signals[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, **35**(2): 2118-2132
- [20] CHEN Z L, WU Z H, CHEUNG W K, *et al.* Mshtans: Multi-scale hypergraph transformer with time-series decomposition for temporal anomaly detection[C]//Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2025: 274-285
- [21] 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 (ICDM). Sorrento: IEEE, 2020: 841-850
- [22] LIU X H, LI X L, LI Y F, *et al.* RTdetector: deep transformer networks for time series anomaly detection based on reconstruction trend[C]//Proceedings of the Thirty-Fourth International Joint Conference on Artificial Intelligence. Montreal: IJCAI, 2025: 5788-5796
- [23] ZHANG C L, ZHOU T, WEN Q S, *et al.* TFAD: A decomposition time series anomaly detection architecture with time-frequency analysis[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta: Association for Computing Machinery, 2022: 2497-2507
- [24] 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



平凡 男，2000 年 6 月出生于河北省邯郸市，现为中国科学院国家空间科学中心在读硕士研究生，主要研究方向为空间大数据应用技术。

E-mail: pingfan23@mailsucas.ac.cn



苏举 男，1985 年 5 月出生于天津市，现为中国科学院国家空间科学中心高级工程师，硕士生导师，主要研究方向为卫星智能运控技术和空间大数据应用技术等。

E-mail: suju@nssc.ac.cn

最新录用