

DOI: 10.19650/j.cnki.cjsi.J2413045

# 基于长时间尺度特性建模优化的飞行器遥测 数据集异常检测方法\*

孙家正<sup>1</sup>, 宋宇晨<sup>1</sup>, 崔展博<sup>2,3</sup>, 李桢煜<sup>1</sup>, 王智鹏<sup>1</sup>, 刘大同<sup>1</sup>

(1. 哈尔滨工业大学电子与信息工程学院 哈尔滨 150080; 2. 石家庄海山实业发展总公司 石家庄 050200;  
3. 航空工业西安飞行自动控制研究所 西安 710076)

**摘要:** 飞行器遥测数据是地面判断卫星在轨状态的唯一来源。异常检测有助于飞行器运行过程的视情动态决策,并能有效减少故障。然而,现有方法主要关注短时变化,难以有效识别集合异常模式。针对这一问题,提出了一种基于长时间尺度特性建模优化的飞行器遥测数据集异常检测方法。首先,构建时序关联依赖模型,提取遥测数据片段中的高维时序规律并生成预测结果;然后,利用预测结果与观测数据之间的残差,构建统计模型,提取分布特征并形成异常检测判据;最后,利用迭代预测自动调整模型输入,提升集合异常检测的鲁棒性。通过实际飞行器姿态角数据的验证,结果表明,相比VAE-LSTM模型,异常片段的检出率提升了0.041, F1分数提升了0.039,证明了该方法在提高检测精度和降低漏检率方面的优势,为卫星视情运维提供可靠的基础数据支撑。

**关键词:** 飞行器;遥测数据;异常检测;长时预测

**中图分类号:** TP311 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.4030

## Aircraft telemetry data collective anomaly detection based on long time scale characteristic modeling optimization

Sun Jiazheng<sup>1</sup>, Song Yuchen<sup>1</sup>, Cui Zhanbo<sup>2,3</sup>, Li Zhenyu<sup>1</sup>, Wang Zhipeng<sup>1</sup>, Liu Datong<sup>1</sup>

(1. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China; 2. Shijiazhuang Hai Shan Aviation Electronic Technology Company Ltd., Shijiazhuang 050200, China; 3. AVIC Xi'an Flight Automatic Control Research Institute, Xi'an 710076, China)

**Abstract:** Aircraft telemetry data are the only source for ground-based assessment of satellite in-orbit status. Anomaly detection facilitates condition-based dynamic decision-making during aircraft operations and effectively reduces failures. However, existing methods primarily focus on short-term variations, making it difficult to identify collective anomaly patterns effectively. To address this issue, this article proposes a collective anomaly detection method for aircraft telemetry data based on long time-scale characteristic modeling optimization. First, a temporal correlation model is formulated to extract high-dimensional patterns from telemetry data segments and generate prediction results. Then, using the residuals between the prediction results and observed data, a statistical model is developed to extract distribution characteristics and establish anomaly detection criteria. Finally, iterative prediction is employed to automatically adjust model inputs, enhancing the robustness of collective anomaly detection. Validation using actual aircraft attitude angle telemetry data shows that, compared with the VAE-LSTM model, the proposed method improves the detection rate of anomaly segments by 0.041 and the F1 score by 0.039. These results show the method's advantages in improving detection accuracy and reducing missed detections, providing reliable data support for condition-based satellite operations and maintenance.

**Keywords:** aircraft; telemetry data; anomaly detection; long-term prediction

## 0 引言

随着我国航天事业的快速发展变革,卫星“快速研

制、长时服役”已成为主流趋势<sup>[1]</sup>。根据中国航天科技集团有限公司<sup>[2]</sup>公布的数据,2022年中国航天共实施64次发射任务,发射航天器数量188个,2023年实施67次发射任务,研制发射航天器221个,2024年全年发射次数

预计达到 100 次。相应地,状态监测和健康管理技术,就成为卫星在轨视情维护、动态任务规划和在轨延寿及可靠性提升的关键支撑性技术。

异常是指数据中不符合预期正常行为的一种模式,而异常检测是指绘制一个表示正常行为的区域,并将任何不属于该区域的观测值标记为异常的过程<sup>[3]</sup>。卫星遥测数据的异常类型可以分为单点异常、关联异常、集合异常和多元异常<sup>[4]</sup>。集合异常是指一些单独的数据点虽然本身并非异常,但当它们作为一个集合共同出现时,被视为异常。这些相关联的数据点组成的集合即被称为集合异常,具体表现方式见 1.3 节。目前,卫星遥测数据异常检测的研究<sup>[5]</sup>已引起了国内外学者的广泛关注,对遥测数据进行异常检测的方法分为 4 大类:基于预设阈值、基于专家系统、基于物理模型和基于数据驱动的异常检测。

预设阈值检测是传统且广泛使用的异常检测方法,通常由地面站工作人员手动设置阈值。美国航空航天局的容错任务规划体系<sup>[6]</sup>为各种遥测参数预定义阈值,当被监测参数超出范围时即标记异常。这种方法操作简单,但针对不同设备需分别设定阈值,对复杂数据处理效率较低;专家系统通过知识库和推理机制模拟领域专家进行诊断。例如美国航空航天公司的航天器环境异常专家系统<sup>[7]</sup>,其单个模块针对单卫星轨道的航天器进行故障诊断,但专家系统过于依赖固定规则,对新工况不具备普遍性,难以推广应用;基于物理模型的异常检测利用系统物理特性,通过模型输出值与观测值的差异识别异常。美国科罗拉多大学的 Bennet 等<sup>[8]</sup>基于太空垃圾对航天器动力学影响的物理建模,检测遥测数据中异常。然而,此类方法通常针对特定异常原因,通用性较差。

基于数据驱动的异常检测是一种利用数据和算法来识别异常行为或事件的方法。这种方法通常涉及收集数据,然后使用机器学习、深度学习或统计分析等方式来建立模型,根据标记异常采用的方法可分为基于相似性度量、基于支持度和基于模型偏差 3 种方法。基于相似性度量方法通过测试样本与正常样本的相似程度检测异常,常用无监督方法有单类支持向量机<sup>[9]</sup>、k-均值聚类算法<sup>[10-11]</sup>、孤立森林<sup>[12-13]</sup>等。Shi 等<sup>[14]</sup>提出一种无监督多变量时间序列异常检测框架,针对变量间的相关性和重要性进行聚类建模。该方法对数据质量依赖较高,且在检测复杂动态时序数据时存在局限。基于支持度的方法通过计算测试样本在正常样本中出现的概率来设定阈值,常用方法有高斯混合模型<sup>[15]</sup>、贝叶斯方法<sup>[16]</sup>等。Wang 等<sup>[17]</sup>提出了一种融合时间关联历史数据和空间关联监测数据的高斯混合模型异常检测方法。此类方法对未知长度的集合异常适应性较好,但需要将时间序列转

化为离散特征,可能导致信息缺失。基于模型偏差的方法通过构建模型,以测试样本与模型输出偏差作为判断依据,常用方法有长短期记忆网络<sup>[18-19]</sup>、极限学习机<sup>[20-21]</sup>、自编码器<sup>[22-24]</sup>、数字孪生<sup>[25-26]</sup>等。Liu 等<sup>[27]</sup>针对高维数和变量间复杂的相关性而效果不佳的问题,提出一个基于时间卷积网络的航天器多变量时间序列数据异常检测框架。此类方法的优点是测试效率较高,但其检测性能依赖于模型的准确性和阈值的设定方式。

综合上述方法,不同检测方法的阈值划分各有侧重:预设阈值和专家系统基于经验规则;物理模型基于模型输出与观测值差异;数据驱动方法则根据统计量、概率或预测残差划分。然而,当前研究主要面临以下两大挑战:

1) 现有异常检测方法较难兼顾短时序卫星遥测数据和长周期数据,尤其是长时间尺度变化趋势的挖掘能力,需要一种针对集合异常模式的异常检测模型。

2) 在遥测数据的异常检测中,传统异常阈值设定方法主要依赖领域专家的经验或基于模型提取数据差异特征进行人为划分,或者简单地使用残差设定阈值。因此在处理集合异常时难以应对区间化的异常情况。

Informer 模型<sup>[28]</sup>针对长时间尺度特性预测,可以捕捉输入序列的长距离依赖关系,便于学习长时间尺度特性序列的内在关联。因此提出的方法以 Informer 作为时序模型预测,针对异常模式提取长期数据内在关联,生成预测结果。同时,为了解决卫星遥测数据中集合异常模式的检测难题,构建了以残差分布、残差均值和残差均方误差为基础的统计模型。该模型将时序模型的预测结果与实际观测值的残差作为输入,输出相应的异常检测阈值,通过此统计模型解决了集合异常模式的判别问题。

此外,提出了迭代预测检验方法。首先对正常数据的趋势进行预测,并基于预测结果的误差特征建立统计模型,确定异常判据的阈值。随后,对目标数据进行迭代预测,在识别遥测数据集异常的过程中,根据检测结果自动反馈和调整时序预测模型的下一轮输入,从而排除异常数据对预测结果的干扰。通过这种迭代预测检验,不仅实现了长时序的精准预测,还有效确定了异常判别的标准。

## 1 卫星遥测数据分析及异常模式

### 1.1 卫星姿轨控系统工作原理与异常原因

卫星在轨运行时,传感器获取实时姿态信息,控制计算机通过姿态控制算法计算调整量,并由执行器完成姿态调整,例如通过控制力矩陀螺实现滚动、俯仰和偏航。当遥测数据持续错误时,控制计算机机会基于错误数据计算调整命令,可能导致执行器误操作,加剧异常影响,因

此需要高效的异常检测方法。遥测数据出现异常的原因如下:

1) 传感器可能会因故障或环境因素导致测量误差,从而产生连续的集合异常数据。

2) 卫星在轨运行时,会受到外部环境(如太阳辐射、地磁场、宇宙尘埃等)的影响,这些影响可能会在短时间内导致传感器数据异常。

## 1.2 卫星姿态角遥测数据

选取实际卫星的滚动轴姿态角和偏航轴姿态角数据集进行分析。滚动轴旋转是指卫星围绕其  $X$  轴的旋转运动,通常沿着卫星的长度方向;偏航轴旋转是指卫星围绕其  $Z$  轴的旋转运动,通常垂直于卫星的平面。如果姿态角数据出现集合异常,可能导致姿态角逐渐偏离预定的控制参数。这种缓慢的姿态漂移将直接影响卫星的定位精度,使其无法准确指向地面目标或其他卫星,从而导致观测数据产生偏差或失真。其中滚动轴姿态角样本如图 1 所示。




图 1 滚动轴姿态角部分样本

Fig. 1 Roll axis attitude angle partial sample

图 1 展示了滚动轴姿态角样本 2011 年 2 月 16 日 7 点 56 分~17 日 8 点 55 分期间的变化,样本以分钟为单位取样,约 1 500 个采样点。可以看出,滚动轴姿态角周期约为 12 h,最大幅值差为  $0.189^\circ$ 。偏航轴姿态角样本如图 2 所示。




图 2 偏航轴姿态角部分样本

Fig. 2 Yaw axis attitude angle partial sample

图 2 展示了偏航轴姿态角样本 2011 年 4 月 26 日 9 点 23 分~27 日 10 点 22 分期间偏航轴姿态角的变化,样本同样以分钟为单位取样,约 1 500 个采样点,与滚动轴样本不同,该样本的周期约为 6 h,最大幅值差为  $0.225^\circ$ 。

实验使用的完整数据集包含单点异常和集合异常 2 种异常类型,数据样本分布情况如表 1 所示。

表 1 实验数据

Table 1 Experiment data

数据类型	滚动轴姿态角	偏航轴姿态角
样本区间	(0~6 400)	(0~10 844)
正常样本区间	(0~4 911)	(0~9 150)
异常样本区间	(4 912~6 400)	(9 151~10 844)

## 1.3 卫星遥测数据异常模式

在卫星运行过程中,受姿态、通信状态及环境条件等因素的影响,地面接收到的遥测数据可能会出现单点异常和集合异常等多种类型。其中,集合异常指的是某些数据点本身无异常,但作为整体却表现出异常特性。这类异常是本文异常检测方法的主要研究对象。与单点异常不同,集合异常涉及多个数据点,要求模型能够捕捉数据的长期依赖关系,对检测方法提出了更高的挑战。滚动轴姿态角集合异常如图 3 所示。




图 3 滚动轴数据集异常

Fig. 3 Collective anomaly of roll axis data

如图 3 所示,滚动轴姿态角从 2011 年 2 月 16 日 15 点 48 分~16 日 16 点 13 分出现集合异常,该段数据整体偏离了正常运行轨迹,表现出异常特性。偏航轴姿态角集合异常如图 4 所示。

如图 4 所示,偏航轴姿态角从 2011 年 4 月 26 日 17 点 16 分~26 日 17 点 41 分出现集合异常,该段数据平稳性显著下降,同时波动变化突出。




图 4 偏航轴数据集异常

Fig. 4 Collective anomaly of yaw axis data

## 2 基于长时间尺度特性建模优化的卫星遥测数据集异常检测方法

在卫星遥测数据中,片段数据的集合异常阈值难以确定。为解决这一问题,本文采用了基于长时间尺度特性建模优化的集合异常检测方法,整个方法分为 3 个主要部分:时序模型训练、统计模型建立和基于迭代预测的集合异常检测,流程如图 5 所示。

用上一轮的预测值;否则,继续使用测试集的观测值作为输入。通过这种迭代方式,实现长时间尺度特性的预测,并完成卫星遥测数据的集合异常检测。

### 2.1 时序模型训练

时序模型的结构主要分为两部分,即编码器层和解码器层,模型的工作原理如图 6 所示。

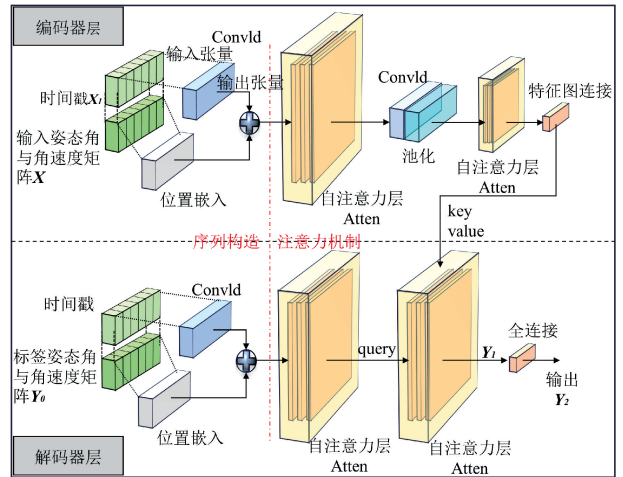


图 6 时序预测原理

Fig. 6 Schematic diagram of time series prediction

从图 6 中可以看出,编码器和解码器均包含序列构造与注意力机制两个主要步骤。编码器通过输入矩阵  $X$  (包括姿态角和角速度) 进行卷积处理,实现维度变换,从而提取多维特征。为了充分捕捉时间序列的周期性、趋势性和季节性特征,模型将时间戳编码为特征向量,并将这些时间特征嵌入处理后的数据中。训练过程中,通过并行计算捕获输入序列中的长距离依赖关系,同时采用随机采样、数据填充和均值赋值等策略优化注意力机制的计算,最后通过池化操作降低计算复杂度。解码器层以标签矩阵  $Y_0$  (包括姿态角和角速度) 为输入,结合编码器输出的特征矩阵,将输出的向量  $Y_1$  (姿态角) 经线性变化得到最终预测结果  $Y_2$  (姿态角)。本节将重点介绍序列构造与注意力机制的实现细节。

#### 1) 序列构造

在时序模型训练过程中,编码器和解码器需要接收经过预处理的输入数据。与传统神经网络模型不同,为了更好地学习卫星遥测数据的内在相关性并适应较长的输入序列,时序模型对数据进行非顺序化处理。故需要用位置编码表示序列中不同位置的信息关系。

##### (1) 位置嵌入

将输入数据的时间戳与数值部分分离,对输入矩阵  $X$  的内部元素的位置进行编码,奇数位和偶数位的编码方式如式(1)和(2)所示。

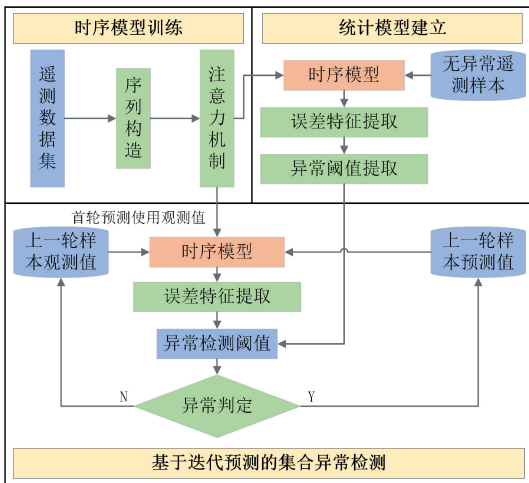


图 5 集合异常检测流程

Fig. 5 Flow chart of collective anomaly detection

在时序模型训练过程中,首先对数据集进行位置编码并嵌入时间特征,然后通过编码器层和解码器层构建时序模型。接着,将无异常的遥测数据样本输入到模型中以获得预测结果,并进一步获取这些预测结果的误差特征,将其输入到统计模型中提取异常检测的阈值。接下来,使用测试集样本输入到时序模型中进行首轮预测。对首轮预测结果应用统计模型提取特征,并依据设定的异常阈值进行判定。如果判定为异常,则次轮输入将使

$$pe(\mathbf{pos}, 2i) = \sin\left(\frac{\mathbf{pos}}{10\,000^{\frac{2i}{d}}}\right) \quad (1)$$

$$pe(\mathbf{pos}, 2i + 1) = \cos\left(\frac{\mathbf{pos}}{10\,000^{\frac{2i}{d}}}\right) \quad (2)$$

式中:  $\mathbf{pos}$  表示位置向量,  $i$  为数据索引, 取值范围为  $0 \leq 2i < d$ ,  $d$  为模型设置的维度常量。通过上述过程, 使输入数据存储位置信息, 并输入到注意力机制中。

## (2) 时间戳卷积

将数据的时间戳标签向量  $\mathbf{X}_1$  转换为一维卷积层的输出结果, 具体如式(3)所示。

$$\text{Convld}(\mathbf{X}_1, \mathbf{W})_{(i,j)} = \sum_{m=0}^{C_{in}-1} \sum_{k=0}^{K-1} \mathbf{X}_{1(i,m,s,j+k)} * \mathbf{W}_{(j,m,k)} + b_j \quad (3)$$

式中: 变量  $i, j$  为输出张量的元素, 输入张量  $\mathbf{X}_1$  的形状为  $(N, C_{in}, L_{in})$ , 卷积核  $\mathbf{W}$  的形状为  $(C_{out}, C_{in}, K)$ , 输出张量的形状为  $(N, C_{out}, L_{out})$ , 其中  $N$  为批量大小,  $C_{out}$  为输出通道数,  $L_{out}$  为输出序列长度,  $K$  为卷积核大小,  $b_j$  表示第  $j$  个输出通道的偏置项,  $s$  是卷积步幅。

输出序列的长度  $L_{out}$  的计算方式如式(4)所示。

$$L_{out} = \left\lfloor \frac{L_{in} + 2 \times \text{padding} - K}{\text{stride}} + 1 \right\rfloor \quad (4)$$

综上所述, 时间戳标签  $\mathbf{X}_1$  经过卷积处理后, 与位置编码信息一起输入到注意力机制中。在解码器中, 对标签数据的姿态角和角速度矩阵  $\mathbf{Y}_0$  应用类似的卷积操作, 从时间特征中提取有效信息, 并与编码器处理后的特征结合, 用于预测结果。

## 2) 注意力机制

通过注意力机制操作, 时序模型能够高效捕捉输入序列中的长距离依赖关系, 其核心思想是通过概率抽样来选择重要的查询键对, 从而降低计算复杂度。

为数值特征赋予查询矩阵  $\mathbf{Q}$  (query)、键矩阵  $\mathbf{K}$  (key) 和值矩阵  $\mathbf{V}$  (value)。查询  $\mathbf{Q}$  与  $\mathbf{K}$  之间的关联程度, 将查询向量  $q_i$  与键矩阵  $\mathbf{K}$  的键向量  $\mathbf{K}_{\text{sample}}$  进行内积计算并形成注意力分数, 如式(5)所示。

$$\text{Score}(\mathbf{Q}, \mathbf{K}_{\text{sample}}) = \mathbf{Q}\mathbf{K}_{\text{sample}}^T \quad (5)$$

根据注意力分数选择分数较高的  $U$  项, 计算注意力权重并对值矩阵  $\mathbf{V}$  求和, 如式(6)和式(7)所示。

$$\text{normal}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (6)$$

$$\text{atten}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \sum_{j \in U} \text{normal}\left(\frac{\text{Score}(q_i, k_j)}{\sqrt{d_k}}\right) v_j \quad (7)$$

式中:  $z_i$  为向量  $\mathbf{Z}$  中第  $i$  个元素,  $d_k$  为矩阵的维度。

编码器通过池化操作丢弃权重较低的数据, 并将多次注意力层的输出结果作为最终的编码结果, 同时作为

解码器的输入。在解码器的最后一次注意力机制中, 输出向量  $\mathbf{Y}_1$  (姿态角张量) 经过线性变换后, 输出最终结果的过程如式(8)所示。

$$\mathbf{Y}_2 = \mathbf{Y}_1 \mathbf{W} + \mathbf{b} \quad (8)$$

式中: 张量  $\mathbf{Y}_1$  的形状与式(3)的  $\mathbf{X}_1$  相同, 权重矩阵  $\mathbf{W}$  和偏置向量  $\mathbf{b}$  的形状同样与式(3)相同。

## 2.2 统计模型建立

得到时序模型后, 将无异常的卫星遥测数据样本输入到训练好的模型中进行预测, 对预测结果进行统计分布处理并建立统计模型, 实现异常阈值的提取。

### 1) 误差特征提取

单次预测的输出结果向量  $\hat{\mathbf{Y}}_i = (\hat{y}_{i1}, \hat{y}_{i2}, \dots, \hat{y}_{in})$ , 其中  $i$  为预测次数,  $n$  为单次预测的点数, 与之对应的是观测值  $\mathbf{Y}_i = (y_{i1}, y_{i2}, \dots, y_{in})$ , 二者作差得到残差矩阵  $\mathbf{E}_{ki}$ , 如图7所示。




图7 误差特征提取

Fig. 7 Extraction of error feature

对残差矩阵进行特征提取, 包括3种方法。

### (1) 残差分布

残差分布能够全面反映数据偏离正常状态的情况, 通过分析整体分布特征, 有助于发现异常。尤其是在多个数据点同时出现轻微异常时, 残差分布可以通过统计偏离程度和频率, 有效识别集合异常的存在。

通过拟合残差矩阵的数据分布, 并利用均值和标准差进行趋势分析, 残差分布采用正态分布进行拟合, 其概率密度函数为:

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (9)$$

式中:  $\mu$  为正态分布的均值,  $\sigma^2$  为方差。通过最大似然估计计算模型参数, 使观测数据出现的概率最大:

$$\mu = \frac{1}{n} \sum_{j=1}^n r_j \quad (10)$$

$$\sigma^2 = \frac{1}{n} \sum_{j=1}^n (r_j - \mu)^2 \quad (11)$$

式中:  $n$  为残差矩阵  $\mathbf{E}_{ki}$  的样本数, 根据式(9)正态分布的特性, 确定残差分布与标准差的关系。

### (2) 残差均值处理

残差分布适用于检测整体变化趋势, 但对整体性偏

差的敏感性不足,因此需要引入残差均值处理。通过计算所有残差的均值,评估数据的整体偏离程度。该方法对趋势性偏移或长期变化敏感,能检测出集合异常中的持续性偏差,处理过程如式(10)所示。

### (3) 均方误差处理

由于均值只提供了预测结果的整体平均水平,并没有考虑预测结果的分布情况,如果预测结果的分布存在较大的偏差,均值可能无法准确反映预测的准确性,因此采用均方误差(mean squared error, MSE)处理。如式(12)所示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

式中:  $y_i$  为观测值;  $\hat{y}_i$  为预测值。

均方误差在放大显著偏差点影响的同时,能够敏感地捕捉集合异常中的局部显著偏差,用于快速识别显著异常点。

### 2) 异常阈值提取

预测残差服从于正态分布,根据式(9)~(12)计算单次预测结果的残差均值和标准差,并根据均值  $\mu$  和标准差  $\sigma$  设定残差分布的阈值  $K$ ,以检测异常点:

$$\begin{aligned} K_h &= \mu + p\sigma \\ K_l &= \mu - p\sigma \end{aligned} \quad (13)$$

式中:  $p$  表示正态分布数据偏离均值的程度。

在正态分布中,取  $p = 1, 2, 3$  对应的数据覆盖率分别为 68.27%、95.45% 和 99.73%。由于残差分布不一定严格服从于正态分布,因此将通过实验验证取值合理性。其中  $p$  取 1 时适合敏感性较高的场景,可检测轻微异常,但误报率较高。 $p$  取 3 时适用于检测显著异常,避免误报。 $p$  取 2 时对误报和漏报进行平衡。

### 2.3 基于迭代预测的集合异常检测

在确定 3 种异常检测阈值后,对遥测数据样本进行预测,并根据统计模型提取误差特征,判断单次预测结果是否超出阈值。若检测到异常,则将下一轮预测的输入值替换为当前轮次的预测输出值,同时标记异常区间。预测流程伪代码如表 2 所示。

检测结果正常时,下一轮预测的输入值为:

$$\mathbf{X}_{k+1} = \begin{Bmatrix} \hat{y}_k^1 & \hat{y}_k^2 & \cdots & \hat{y}_k^n \\ d_{k+1}^1 & d_{k+1}^2 & \cdots & d_{k+1}^n \end{Bmatrix} \quad (14)$$

若不存在异常,则使用观测数据继续进行下一轮的预测,输入值为:

$$\mathbf{X}_{k+1} = \begin{Bmatrix} y_k^1 & y_k^2 & \cdots & y_k^n \\ d_{k+1}^1 & d_{k+1}^2 & \cdots & d_{k+1}^n \end{Bmatrix} \quad (15)$$

式中:  $y_k$  为第  $k$  轮观测值;  $\hat{y}_k$  为第  $k$  轮预测值;  $d_{k+1}$  为第  $k+1$  轮输入参数。

表 2 迭代预测伪代码

Table 2 Pseudocode of iterative prediction

迭代预测流程
输入: $D1$ : 训练集; $D2$ : 观测值; $L1$ : 测试集长度; $L2$ : 单次预测长度; $T1$ : 均方差阈值; $T2$ : 残差均值阈值; $T3$ : 残差分布阈值;
输出: $D3$ : 预测值; $M1$ : 均方差; $M2$ : 均值误差; $M3$ : 误差趋势;
for $i=1 \rightarrow i = L1/L2$ do
if $i == 1$ then
//首轮预测使用训练集数据
$D3, M1, M2, M3 = \text{Informer}(D1)$ ;
if $M1 > T1$ or $M2 > T2$ or $M3 > T3$ then
//任何一项大于阈值均判定为异常,用观测值预测下轮。
$D3, M1, M2, M3 = \text{Informer}(D2)$ ;
else
$D3, M1, M2, M3 = \text{Informer}(D3)$ ;

## 3 实验及结果分析

### 3.1 实验设计及评价指标

#### 1) 实验设置

实验通过正常样本输入时序模型,进行长时间尺度特性预测,分析模型对数据周期性特征的捕捉能力。为此,根据数据周期长度分别选取 24 和 48 点作为输入长度,进行对比实验,验证时序模型在捕捉长时间关系特性方面的效果。

单次预测结果将输入统计模型,用于确定异常检测的阈值,并对统计模型中的参数  $p$  进行实验验证,以确定其合理取值。此外,实验探讨了残差均值、均方误差和残差分布 3 种统计特征结合使用的必要性,实验数据见表 1。

#### 2) 异常检测与对比分析

在异常样本检测实验中,基于时序模型进行迭代预测。通过残差均值、MSE 和残差分布指标,标记异常区间,并与孤立森林和 VAE-LSTM 方法进行对比分析,从不同维度评估模型的异常检测能力。

#### 3) 评价指标

(1) 使用 MSE 作为正常样本预测的评价指标。MSE 衡量预测值与真实观测值之间的偏差程度,是一种反映预测结果精度的重要统计量。MSE 值越小,表示模型对正常样本的预测结果越精准。其计算公式已在式(12)中给出,此处不再赘述。

(2) 精确度指检测出的异常样本中真正异常样本的比例,即正样本中被正确检测为正样本的比例:

$$Pr = \frac{TP}{TP + FP} \quad (16)$$

式中:  $TP$  表示真正例;  $FP$  表示假正例。

(3) 召回率指所有真正异常样本中被正确检测出的比例,即被检测出的正样本占有所有正样本的比例:

$$Re = \frac{TP}{TP + FN} \tag{17}$$

式中:  $FN$  表示假负例。

(4)  $F1$  分数综合考虑精确度和召回率,是精确度和召回率的调和平均数,公式为:

$$F1 = 2 \times \frac{Pr \times Re}{Pr + Re} \tag{18}$$

### 3.2 实验结果与分析

#### 1) 正常样本长时间尺度特性预测

实验分别对滚动轴和偏航轴数据进行长时特性预测,选取 24 和 48 点为输入长度,以 MSE 作为评价指标,分析单次预测长度对结果的影响,如表 3 所示。

表 3 遥测数据预测分析

Table 3 Analysis of telemetry data prediction

样本类型	预测长度/点	残差均值	均方误差
滚动姿态角	24	0.023 9	$4.84 \times 10^{-6}$
	48	0.014 8	$2.67 \times 10^{-6}$
偏航姿态角	24	0.012 4	$5.52 \times 10^{-6}$
	48	0.012 9	$3.93 \times 10^{-6}$

从表 3 可以看出,随着预测长度的增加,滚动姿态角残差均值明显下降,MSE 值显著降低,48 点预测的效果优于 24 点预测;偏航姿态角残差均值变化不显著,但 48 点预测的 MSE 值低于 24 点预测,说明更长的预测长度有助于提高预测的准确性。

#### 2) 异常样本检测

##### (1) 异常阈值提取

完成正常样本的长时间尺度预测后,利用预测值与观测值的残差,计算残差均值、残差分布和均方误差,依据式(9)~(13)建立统计模型,提取阈值。两种姿态角数据的阈值分布状况如表 4 所示。

表 4 异常检测阈值

Table 4 Threshold of anomaly detection

样本类型	预测长度/点	残差平均数阈值	残差分布阈值	均方误差阈值
滚动姿态角	24	0.035 8	0.047 6	$1.39 \times 10^{-5}$
	48	0.034 2	0.037 9	$6.10 \times 10^{-6}$
偏航姿态角	24	0.023 1	0.039 8	$2.37 \times 10^{-5}$
	48	0.020 6	0.047 6	$1.62 \times 10^{-5}$

表中残差分布阈值由式(13)得出,  $p$  取值为 1,预测

长度根据数据的周期性特征选定;滚动轴姿态角周期约为 720 点,偏航角周期约为 360 点。结果显示,滚动角 24 点预测的残差均值和残差分布阈值较高,MSE 也较大;48 点预测时,残差均值和 MSE 显著降低,表明长时序预测更稳定地捕捉长期变化趋势;偏航角 24 点预测的残差均值和 MSE 较高;48 点预测虽然残差分布阈值增加,但 MSE 显著降低,显示长时序预测在捕捉偏航角长时间变化方面更具优势。综上所述,长时序预测能够减少均方误差并保持预测稳定性。

##### (2) 异常检测方法

确定阈值后,根据图 5 的流程进行迭代预测,对单次预测结果进行检测。若 3 项统计指标中任一项超出阈值,则判定为异常数据,并标记对应区间为异常区间。基于 MSE 的滚动角异常检测结果如图 8 所示。




图 8 基于均方误差的异常检测结果

Fig. 8 Anomaly detection results based on MSE

图 8 中横轴为预测次数,每次预测包含 24 个遥测数据,纵轴为均方误差。检测结果表明:样本中存在两组异常区间,其余区间均为正常值。根据检测结果完成迭代预测,预测结果如图 9 所示。

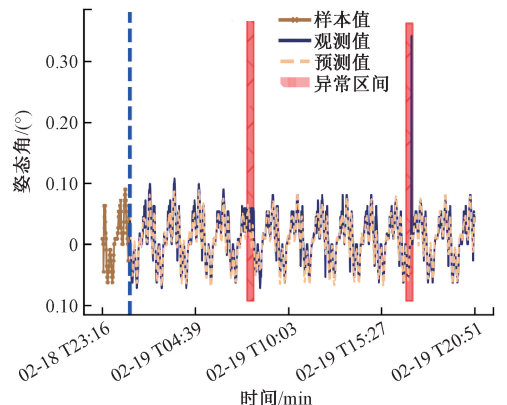


图 9 异常区间标注

Fig. 9 Anomaly interval labeling

图 9 使用方框标记存在异常的区间,左侧的异常区

间对应图 8 的第 18 次预测,为集合异常类型,右侧异常区间对应第 41 次预测,为点异常类型。

(3) 验证取值合理性

为证明残差分布阈值中  $p$  的合理取值, $p$  分别取值 1, 2, 3 生成不同残差分布阈值,在两类异常样本上进行对比实验,检测结果如表 5 所示。

表 5  $p$  取值对检测结果的影响

Table 5 Influence of  $p$  on the detection result

异常样本	评价标准	残差分布 阈值( $p=1$ )	残差分布 阈值( $p=2$ )	残差分布 阈值( $p=3$ )
滚动轴姿态角	PR	0.436	0.375	0.250
偏航轴姿态角	PR	0.375	0.313	0.313

从表中结果可以看出,随着  $p$  取值的增大,异常检测敏感度逐渐下降,模型捕捉到的异常数量减少。当  $p$  取值为 1 的时候,模型对异常数据的检测效果最佳,检测精确度较高,后续实验采用  $p=1$  为默认取值。

(4) 验证 3 种阈值组合选择合理性

通过单独使用残差均值阈值、残差分布阈值、均方误差阈值,以及 3 种阈值的组合方法,对两类异常样本部分数据进行检测,检测结果如表 6 所示。

表 6 阈值检测效果对比

Table 6 Comparison of threshold detection effect

异常样本	评价标准	残差平 均阈值	残差分布 阈值	均方误 差阈值	组合 阈值
滚动轴姿态角	PR	0.429	0.436	0.643	0.813
偏航轴姿态角	PR	0.500	0.375	0.615	0.938

从结果可知,两种数据的组合检测结果优于任何一种阈值的独立检测,因此联合使用多种标准能增强异常检测的鲁棒性和灵敏度。

(5) 样本检测结果

基于以上方法,对滚动轴姿态角和偏航轴姿态角样本进行异常检测,使用 24 点预测、48 点预测、孤立森林和 VAE-LSTM 方法对比,结果如表 7 所示。

依据数据的周期特性,实验采用 24 点预测和 48 点预测进行异常检测。根据表 4 的结论,48 点预测对异常数据更为敏感,因此在体现模型正确识别能力的召回率(recall rate, RE)指标中表现更为出色。然而,在精确度(precision rate, PR)指标中,由于 48 点预测过于敏感,在偏航轴数据上的表现不如 24 点预测。但综合考虑所有指标,24 和 48 点预测的检测结果均优于孤立森林方法。

与 VAE-LSTM 方法相比,本文方法表现出更强的优势。具体而言,24 点预测在偏航轴数据上表现更优,而

表 7 异常检测结果对比

Table 7 Comparison of anomaly detection results

异常样本	评价标准	24 点 预测	48 点 预测	孤立 森林	VAE-LSTM
滚动轴姿态角	PR	0.750	0.813	0.714	0.736
	RE	0.712	0.867	0.688	0.766
	F1	0.729	0.839	0.701	0.751
偏航轴姿态角	PR	0.938	0.625	0.667	0.745
	RE	0.833	0.909	0.625	0.788
	F1	0.882	0.741	0.645	0.766

48 点预测在滚动轴数据上占据优势,显示了方法在集合异常检测方面的更高稳定性和准确性。

与 VAE-LSTM 相比,本方法在精确度指标中平均提升了 0.041,在召回率指标中平均提升 0.053,在二者综合考虑的 F1 分数指标,本文方法平均提升 0.039。

综上所述,本文提出的迭代预测方法能够有效完成长时间尺度特性卫星遥测数据的异常检测,在提高检测准确性的同时,展现出较高的鲁棒性和稳定性。

4 结 论

卫星携带的数据在地球观测、气象预测和通信等领域具有重要意义。卫星异常可能导致资源浪费、设备损坏,甚至与地面失去联系。因此,卫星异常检测是确保卫星正常运行和数据质量的关键环节,提高卫星的异常检测能力至关重要。为此,本文提出了一种基于长时间尺度特性建模优化的卫星遥测数据集异常检测方法。该方法结合时序预测模型与统计模型,通过阈值计算获取异常检测标准,并基于迭代预测的反馈调节输入数据,排除异常干扰,从而实现集合异常的检测。通过实际卫星遥测数据实验验证,该方法能够对长周期数据中的集合异常进行有效标记,为地面站提供可靠的异常告警信息,从而支持卫星视情动态决策的实施。

尽管如此,本文的方法仍有不足。长序列输入虽然能更全面地捕捉数据的长时间尺度特性变化趋势,但也使得方法对异常更加敏感,可能不利于精确度的提升。未来研究将针对这一问题,结合数据分布特性,设计动态阈值以适应不同场景的异常检测需求;同时,针对不同时间尺度的数据,优化模型在长短期特性上的表现,提升方法对复杂时序数据的适应能力。

参考文献

[1] 彭宇,孙树志,姚博文,等. 微小卫星星载综合电子系统技术综述[J]. 电子测量与仪器学报,2021,35(8): 1-11.



- PENG Y, SUN SH ZH, YAO B W, et al. Summary of the technology of integrated electronic system on board microsatellite[J]. *Journal of Electronic Measurement and Instrumentation*, 2021,35(8):1-11.
- [2] CASC. CASC released blue book of China aerospace science and technology activities in 2022[J]. *Aerospace China*, 2022,23(4):52-58.
- [3] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection: A survey [J]. *ACM computing surveys (CSUR)*, 2009,41(3):1541882.
- [4] 彭喜元,庞景月,彭宇,等. 航天器遥测数据异常检测综[J]. *仪器仪表学报*,2016,37(9):1929-1945.  
PENG X Y, PANG J Y, PENG Y, et al. Review on anomaly detection of spacecraft telemetry data[J]. *Chinese Journal of Scientific Instrument*, 2016,37(9):1929-1945.
- [5] 庞景月. 基于概率性预测的航天器遥测数据异常检测方法研究[D]. 哈尔滨工业大学,2019.  
PANG J Y. Probabilistic prediction based anomaly detection method for spacecraft telemetry data [D]. Harbin Institute of Technology, 2019.
- [6] HOPKINS A L, SMITH T B, LALA J H. FTMP—A highly reliable fault-tolerant multiprocess for aircraft[J]. *Proceedings of the IEEE*, 1978,66(10):1221-1239.
- [7] O'BRIEN T P. SEAES-GEO: A spacecraft environmental anomalies expert system for geosynchronous orbit [J]. *Space Weather*. 2009,7(9):1-14.
- [8] BENNET A A, SCHAUB H, CARPENTER R. Assessing debris strikes in spacecraft telemetry: Development and comparison of various techniques[J]. *Acta Astronautica*. 2021,181:516-529.
- [9] HE J H, CHENG ZH J, GUO B. Anomaly detection in telemetry data using a jointly optimal one-class support vector machine with dictionary learning[J]. *Reliability Engineering & System Safety*, 2024,242:109717.
- [10] YAIRI T, TAKEISHI N, ODA T, et al. A data-driven health monitoring method for satellite housekeeping data based on probabilistic clustering and dimensionality reduction [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017,53(3):1384-1401.
- [11] AKBARIAN H, MAHGOUB I, WILLIAMS A. Autoencoder-K-means algorithm for efficient anomaly detection to improve space operations [C]. *2024 International Conference on Smart Applications, Communications and Networking (SmartNets)*, 2024:1-6.
- [12] HARIRI S, KIND M C, BRUNNER R J. Extended isolation forest[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021,33(4):1479-1489.
- [13] XU H Z, PANG G S, WANG Y J, et al. Deep Isolation forest for anomaly detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023,35(12):12591-12604.
- [14] SHI Y F, WANG B, YU Y W, et al. Robust anomaly detection for multivariate time series through temporal GCNs and attention-based VAE[J]. *Knowledge-Based Systems*, 2023,275:110725.
- [15] SOLIGO P, MERKEL G, JORGE I. Ground segment anomaly detection using gaussian mixture model and rolling means in a power satellite subsystem[C]. *Argentine Congress of Computer Science*. Cham: Springer International Publishing, 2021: 254-266.
- [16] CHEN J F, PI D CH, WU ZH Y, et al. Imbalanced satellite telemetry data anomaly detection model based on Bayesian LSTM[J]. *Acta Astronautica*, 2021,180:232-242.
- [17] WANG ZH P, GAO Y J, PANG J Y, et al. Satellite power system anomaly detection based on spatio-temporal uncertainty fusion[C]. *2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS)*, 2023:1-5.
- [18] 董静怡,庞景月,彭宇,等. 集成 LSTM 的航天器遥测数据异常检测方法[J]. *仪器仪表学报*,2019,40(7):22-29.  
DONG J Y, PANG J Y, PENG Y, et al. Spacecraft telemetry data anomaly detection method based on ensemble LSTM[J]. *Chinese Journal of Scientific Instrument*, 2019,40(7):22-29.
- [19] LIN SH Y, CLARK R, BIRKE R, et al. Anomaly detection for time series using VAE-LSTM hybrid model[C]. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020:4322-4326.
- [20] 史欣田,庞景月,张新,等. 基于集成极限学习机的卫星大数据分析[J]. *仪器仪表学报*,2018,39(12):81-91.  
SHI X T, PANG J Y, ZHANG X, et al. Satellite big data analysis based on bagging extreme learning machine[J]. *Chinese Journal of Scientific Instrument*, 2018,39(12):81-91.
- [21] BAIREDDY S, CHAN M W, DESAI S R, et al. Spacecraft time-series online anomaly detection using extreme learning machines [C]. *2022 IEEE Aerospace*

- Conference (AERO), 2022:1547-1555.
- [22] CHOW J K, SU ZH Y, WU J Q, et al. Anomaly detection of defects on concrete structures with the convolutional autoencoder [J]. *Advanced Engineering Informatics*, 2020,45:101105.
- [23] CHENG ZH, WANG S W, ZHANG P, et al. Improved autoencoder for unsupervised anomaly detection [J]. *International Journal of Intelligent Systems*, 2021, 36(12):7103-7125.
- [24] 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.
- LI ZH Y, SONG Y CH, PENG X Y, et al. Contrastive time-series reconstruction method for satellite anomaly detection[J]. *Chinese Journal of Scientific Instrument*, 2024,45(4):17-26.
- [25] 王盟,赵光权,刘大同,等. 卫星电源系统的数字伴飞建模方法[J]. *仪器仪表学报*,2024,45(5):166-178.
- WANG M, ZHAO G Q, LIU D T, et al. Modeling method for digital accompanying flight of satellite power supply system[J]. *Chinese Journal of Scientific Instrument*, 2024,45(5):166-178.
- [26] 庞景月,赵光权. 数字孪生驱动多算法自适应选择的空电源系统故障检测[J]. *电子测量与仪器学报*, 2022,36(6):91-99.
- PANG J Y, ZHAO G Q. Digital twin-driven multi-algorithms adaptive selection for fault detection of space power system[J]. *Journal of Electronic Measurement and Instrumentation*, 2022,36(6):91-99.
- [27] LIU L, TIAN L, KANG Z, et al. Spacecraft anomaly detection with attention temporal convolution networks[J]. *Neural Computing and Applications*, 2023, 35(13):9753-9761.

- [28] ZHOU H Y, ZHANG SH H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting [C]. *35th AAAI Conference on Artificial Intelligence*, 2021,35(12):11106-11115.

## 作者简介



E-mail:hit\_sunjiazheng@163.com

**Sun Jiazheng** received his B. Sc. degree from Harbin Institute of Technology in 2019. He is currently a master in Automatic Test and Control Institute at Harbin Institute of Technology. His main research interests include satellite data intelligent mining and aircraft health status intelligent evaluation, etc.



E-mail:songyuchen@hit.edu.cn

**Song Yuchen** (Corresponding author) received his B. Sc. degree from University of Electronic Science and Technology of China in 2015, and received his Ph. D. degree from Harbin Institute of Technology in 2022. He is currently an associate professor at Harbin Institute of Technology. His main research interests include complex system intelligent sensing and evaluation, intelligent testing information processing, Satellite constellation state monitoring and operating, etc.

**孙家正**,2019年于哈尔滨工业大学获得学士学位,现为哈尔滨工业大学自动化测试与控制研究所硕士研究生,主要研究方向为卫星数据智能挖掘、飞行器健康状态智能评估等。

**宋宇晨**(通信作者),2015年于电子科技大学获得学士学位,2022年于哈尔滨工业大学获得博士学位,现为哈尔滨工业大学副教授,主要研究方向为复杂系统智能感知与评估、智能测试信息处理、卫星星座状态监测与运维等。