

DOI:10.19651/j.cnki.emt.2518327

基于表示学习和动态阈值的航天器异常检测方法^{*}

胡自航 张玉杰 苗强

(四川大学电气工程学院 成都 610065)

摘要: 航天器本身结构复杂且工作环境多变,而针对航天器的异常检测是监测航天器状态,保障航天任务成功执行的关键。由于航天器遥测数据具有非平稳性且包含噪声,因此传统异常检测方法针对遥测数据进行异常检测存在检测精度低、适应性差等问题。本文提出了一种融合表示学习与动态阈值优化的智能异常检测框架,以提升航天器数据异常检测的准确性与可靠性。首先,通过堆叠自编码器对高维时序数据进行非线性降维,提取低维本质特征以抑制噪声干扰;其次,使用神经电路策略模型对特征数据进行建模,利用其仿生稀疏结构与自适应时间常数机制对数据进行预测;最后,引入多目标优化算法动态调整异常判定阈值,兼顾异常检测的精确率与召回率,解决固定阈值在数据分布突变场景下的检测效果不佳的问题。在仿真数据集的漂移异常检测实验中,本文所提方法的异常检测的F1分数比LSTM、Transformer和TFT 3种方法分别高了65.1%、50.5%和8.8%。而在真实卫星数据集的实验中,本文所提方法较3个对比方法的F1分数分别高了53.0%、51.0%和41.0%。在两个航天器数据集上的实验表明,本方法较对比方法显著提高了预测准确性。本文所提方法为航天器在轨自主健康管理提供了一个新的技术途径,对提升深空探测任务的安全性与可靠性具有重要意义。

关键词: 异常检测;表示学习;神经电路策略;航天器**中图分类号:** TP206+.3; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Spacecraft anomaly detection method based on representation learning and dynamic threshold optimization

Hu Zihang Zhang Yujie Miao Qiang

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Spacecraft exhibit intricate structural designs and operate in highly dynamic environments, where anomaly detection plays a pivotal role in monitoring spacecraft status and ensuring mission success. Traditional anomaly detection methods face challenges of low accuracy and poor adaptability when applied to non-stationary and noise-contaminated telemetry data. This paper proposes an intelligent anomaly detection framework integrating representation learning with dynamic threshold optimization to enhance detection accuracy and reliability. The methodology comprises three key components. First, a stacked autoencoder performs nonlinear dimensionality reduction on high-dimensional time-series data to extract low-dimensional intrinsic features while suppressing noise interference. Second, a Neural Circuit Policies model with bio-inspired sparse connectivity and adaptive time constant mechanisms is employed for temporal pattern modeling and prediction. Finally, a multi-objective optimization algorithm dynamically adjusts anomaly thresholds to balance precision and recall, effectively addressing the performance degradation of fixed thresholds under abrupt data distribution shifts. In the drift anomaly detection experiments on the simulation dataset, the proposed method achieved F1-score improvements of 65.1%, 50.5% and 8.8% compared to LSTM, Transformer and TFT methods, respectively. For the real-world satellite dataset, our approach demonstrated superior performance with F1-score enhancements of 53.0%, 51.0% and 41.0% over the same three baseline methods. Experimental results on two spacecraft datasets demonstrate that the proposed method significantly improves prediction accuracy compared to baseline methods. The proposed framework establishes a novel technical approach for on-orbit autonomous health management of spacecraft, with substantial implications for enhancing the safety and reliability of deep space exploration missions.

Keywords: anomaly detection; representation learning; neural circuit policies; spacecraft

0 引言

航天器作为高度集成的复杂系统,承担着众多重要任

务,因此对安全性和可靠性要求极高^[1]。然而,航天器在轨运行环境极端复杂,其关键组件易因硬件老化、软件故障或环境扰动引发异常,影响其性能和可靠性^[2]。因此,开发出

有效的航天器异常检测方法对于保障航天器的安全运行至关重要^[3]。

当前的航天器异常检测方法主要包括基于物理模型的方法、基于专家知识的方法和基于数据驱动的方法^[4-5]。其中,基于数据驱动的航天器异常检测方法通过挖掘数据中的潜在规律检测异常,突破了传统方法对物理模型和规则的依赖,可以提高异常检测的准确性^[6]。

在基于数据驱动的航天器异常检测方法中,使用深度学习方法对航天器遥测数据进行异常检测的方法是当前研究的一个重点。Liu 等^[7]提出了一种基于时间卷积网络的异常检测方法,结合动态图注意力机制以及时间卷积网络,检测遥测数据中的异常。Li 等^[8]提出了一种基于深度置信网络的异常检测算法,通过分析电池各个参数之间的相关性,检测航天器储能电池健康状态的异常。Yu 等^[9]提出了一种最大信息系数注意力图网络的方法,分析航天器遥测数据中复杂的时序和维度间关系,从而进行异常检测。

而基于数据驱动的异常检测方法又可以分为基于预测、基于分类和基于聚类的方法,有众多学者使用上述方法进行了异常检测研究。Wang 等^[10]提出了一种航天器太阳能电池阵列异常检测方法,使用集成最小二乘支持向量机来预测遥测数据并识别异常。Su 等^[11]提出了一种基于分类的单传感器异常检测方法,使用基于单类支持向量机和 K 近邻的两阶段算法对数据进行分类,进而进行异常检测。王婵等^[12]提出了一种基于聚类的异常检测方法,通过子空间搜索和两阶段遥测数据聚类处理检测航天器遥测数据的异常。基于分类的方法依赖历史故障标签,基于聚类的方法则侧重于空间分布离群点检测,而由于遥测数据具有时序相关性,基于预测的异常检测方法可以充分利用数据内在规律,从而获得更好的异常检测结果^[13]。

在使用深度学习方法进行基于预测的异常检测时,预测的结果能否反映实际的数据特征将直接关系到异常检测的效果,而使用表示学习方法对时间序列进行预测则是提高预测效果的一个有效的方法。王永康等^[14]提出了一种改进的基于邻域信息的知识表示模型,使用表示学习的方法提取实体及关系的特征,从而提高预测的准确性。赵伟豪^[15]提出了一种基于序列数据表示学习用户行为预测方法,针对多模元素进行多模态表征研究,结合注意力机制表征关联关系,从而实现对用户行为偏好的预测。使用表示学习方法进行时间序列预测的核心优势在于能够从数据中提取高度抽象且低维的潜在表征,从而改善数据预测的效果。

当前的航天器异常检测方法直接使用原始时间序列特征,对高维时序中的噪声与冗余信息敏感,而且传统的固定阈值策略因假设数据分布平稳,难以适应非平稳时序的动态波动,从而导致异常检测效果不佳。针对上述问题,本文所提方法通过堆叠自编码器的非线性表示学习,将原始特征压缩至低维空间,减少数据中的噪声干扰,再使用神经电

路策略(neural circuit policies, NCP)模型对数据进行预测,随后结合动态阈值机制计算最优阈值,对航天器遥测数据进行异常检测。本文的贡献如下:

1) 提出了一种使用表示学习对航天器遥测数据进行预测的方法,先使用堆叠自编码器对原始时间序列数据进行降维,再使用 NCP 模型对航天器遥测数据进行预测;

2) 提出了一种基于多目标优化的异常检测动态阈值机制,通过精确率与召回率的平衡对随机森林模型参数进行优化,从而计算出最优阈值;

3) 通过在两个航天器数据集上的异常检测实验的验证,本文所提异常检测方法可以有效检测出航天器遥测数据中的异常。

本文所提方法在航天器半实物仿真模型的数据集和真实的航天器数据集上进行了实验验证,此方法在航天器异常检测应用中具有较高的检测准确率,为航天器运行安全提供了可靠的技术支持。

1 基本理论

1.1 异常的定义

航天器常见的异常有 4 种类型:突刺异常、静态异常、漂移异常和偏差异常^[16-19]。

1) 突刺异常

突刺异常是指数据在一个很短的时间内获得了一个随机生成的附加值。突刺异常的定义如下:

$$x(t) = \begin{cases} n(t) + a, & t \in \text{anomaly range} \\ n(t), & \text{其他} \end{cases} \quad (1)$$

其中, $x(t)$ 表示航天器的时间序列数据, a 为航天器数据中随机获得的附加值, $n(t)$ 为正常数据。

2) 偏差异常

偏差异常是指数据在一段时间内与原始数据产生了偏差,与突刺异常相比,其持续时间较长,其定义如下:

$$x(t) = \begin{cases} n(t) + a, & t \in \text{anomaly range} \\ n(t), & \text{其他} \end{cases} \quad (2)$$

其中, $x(t)$ 表示航天器的时间序列数据, a 为偏差值, $n(t)$ 为正常数据。

3) 静态异常

静态异常是指数据在一段时间内变为一个静态的常量,其定义如下:

$$x(t) = \begin{cases} a, & t \in \text{anomaly range} \\ n(t), & \text{其他} \end{cases} \quad (3)$$

其中, $x(t)$ 表示航天器的时间序列数据, a 为一个静态的常量, $n(t)$ 为正常数据。

4) 漂移异常

漂移异常是指数据随着时间逐渐变化,超过了正常值的范围,其定义如下:

$$x(t) = \begin{cases} n(t) + kt, & t \in \text{anomaly range} \\ n(t), & \text{其他} \end{cases} \quad (4)$$

其中, $x(t)$ 表示航天器的时间序列数据, k 为一个常数, $n(t)$ 为正常数据。

1.2 堆叠自编码器

自编码器(autoencoder, AE)的核心思想最早可追溯到 Rumelhart 等^[20]于 1986 年在一篇经典论文中提出的自动关联器(auto-associator), 该结构通过编码-解码的过程学习数据低维表示。此论文提出通过反向传播训练多层网络, 并首次描述了编码-解码结构, 为自编码器奠定了理论基础。

堆叠自编码器(stacked autoencoder, SAE)作为自编码器的改进算法, 其概念最早由 Hinton 等^[21]于 2006 年提出。此论文提出通过逐层训练自编码器来初始化深度网络, 通过分层预训练策略解决深度网络梯度消失问题, 论文中展示了堆叠自编码器在非线性降维和深度网络预训练中的有效性。

其核心步骤分为编码和解码阶段, 具体步骤如下:

假设输入数据为 $\mathbf{x} \in \mathbb{R}^d$, 编码阶段进行逐层非线性变换:

$$\mathbf{h}^{(1)} = f(\mathbf{W}^{(1)} \mathbf{x} + \mathbf{b}^{(1)}) \quad (5)$$

$$\mathbf{h}^{(2)} = f(\mathbf{W}^{(2)} \mathbf{h}^{(1)} + \mathbf{b}^{(2)}) \quad (6)$$

其中, $\mathbf{W}^{(k)}$ 为第 k 层权重矩阵, $\mathbf{b}^{(k)}$ 为偏置向量, $f(\cdot)$ 为 ReLU 激活函数。

在解码阶段进行对称结构重建:

$$\mathbf{z}^{(1)} = g(\mathbf{V}^{(1)} \mathbf{h}^{(2)} + \mathbf{c}^{(1)}) \quad (7)$$

$$\hat{\mathbf{x}} = g(\mathbf{V}^{(2)} \mathbf{z}^{(1)} + \mathbf{c}^{(2)}) \quad (8)$$

其中, $\mathbf{V}^{(k)}$ 为第 k 层解码层的权重矩阵, $g(\cdot)$ 为 Sigmoid 函数。

目标函数设置为:

$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{i=1}^N \| \mathbf{x}_i - \hat{\mathbf{x}}_i \|^2 + \lambda \sum_{k=1}^2 (\| \mathbf{W}^{(k)} \|_F^2 + \| \mathbf{V}^{(k)} \|_F^2) \quad (9)$$

其中, $\theta = \{\mathbf{W}, \mathbf{b}, \mathbf{V}, \mathbf{c}\}$ 为可学习参数, λ 为 L2 正则化系数, $\| \cdot \|_F$ 表示 Frobenius 范数。

1.3 神经电路策略

神经电路策略(neural circuit policies, NCP)由 Lechner 等^[22]于 2020 年提出, 其灵感来源于线虫的神经系统结构。线虫的神经系统以稀疏连接和分层拓扑为特征, 能够通过极少的神经元完成复杂的行为控制。NCP 将生物神经网络的稀疏性、层级性和动态适应性引入神经网络, 以实现高效、鲁棒且可解释的自主控制。

而 NCP 通过 4 层结构和随机连接规则构建稀疏网络, 具体步骤如下:

步骤 1) 层级划分

定义 4 类神经元, 其中, 感觉神经元 N_s 负责接收外部输入; 中间神经元 N_i 负责整合感觉层信号; 命令神经元 N_c 负责生成决策; 运动神经元 N_m 负责输出控制信号。

步骤 2) 层间突触连接

对每对相邻层(此处以 $N_s \rightarrow N_i$ 为例), 执行以下操作:

对每个源神经元 $s \in N_s$, 从 N_i 中按均匀分布随机选择 n_{syn} 个目标神经元 $t \in N_i$; 每个突触的极性 p 服从伯努利分布 $\text{Bernoulli}(p_2)$, 即 $P(p = +1) = p_2, P(p = -1) = 1 - p_2$; 权重 w_{st} 从均匀分布 $\mathcal{U}(-0.1, 0.1)$ 中采样。

对于 $s \in N_s, t \in N_i$, 连接概率为:

$$P(\text{连接}) = \frac{n_{\text{syn}}}{|N_i|} \quad (10)$$

其中, $|N_i|$ 为中间层神经元总数。

步骤 3) 补全零连接

对每个目标神经元 $t \in N_i$, 若其未收到任何突触连接, 则从源层 N_s 中随机选择 m_{syn} 个神经元补全连接, 规则同步骤 2)。

步骤 4) 递归连接

在命令神经元 N_c 内部, 添加 l_{syn} 个递归突触, 随机选择 l_{syn} 对神经元 $(c, c') \in N_c \times N_c$, 极性 p 服从伯努利分布 $\text{Bernoulli}(p_2)$ 。

整体连接密度的计算方法为:

$$d =$$

$$\frac{\text{总突触数}}{|N_s| |N_i| + |N_i| |N_c| + |N_c| |N_m| + |N_c|^2} \quad (11)$$

若 d 取 0.1, 则实现 90% 稀疏性。

步骤 5) 数值求解与训练

进行半隐式欧拉离散化, 将 LTC(liquid time-constant) 的常微分方程离散化为时间步长 Δt , 可得到:

$$x_i(t + \Delta t) = \frac{C_{m_i} x_i(t) + \Delta t [g_i x_{\text{leak}} + \sum_j w_{ij} \sigma(x_j(t)) E_{ij} + I_{\text{ext}}]}{C_{m_i} + \Delta t (g_i + \sum_j w_{ij} \sigma(x_j(t)))} \quad (12)$$

通过自动微分反向传播梯度, 损失函数为均方误差(MSE):

$$\mathcal{L} = \frac{1}{T} \sum_{t=1}^T (y_{\text{true}}(t) - y_{\text{pred}}(t))^2 \quad (13)$$

其中, $y_{\text{pred}}(t)$ 为运动层输出。

2 所提异常检测方法

2.1 数据预测方法

对于给定时间序列数据 $\{s_i\}_{i=1}^T$, 通过滑动窗口构造监督学习样本对 (\mathbf{X}_i, y_i) , 滑动窗口大小设置为 W , 步长 $S = 1$, 则第 i 个样本的输入特征为:

$$\mathbf{X}_i = [s_i, s_{i+1}, \dots, s_{i+W-1}]^T \in \mathbb{R}^W, i = 1, 2, \dots, T-W \quad (14)$$

输出标签为对应窗口后一时刻的观测值:

$$y_i = s_{i+W} \in \mathbb{R} \quad (15)$$

使用堆叠自编码器提取低维时序特征, 具体过程在 1.2 节中已经给出, 输入特征在编码过程中被表示成低维向量 \mathbf{z}_i 。

以低维向量 \mathbf{z}_i 为输入特征, 构建新的监督学习样本对 (\mathbf{z}_i, y_i) , 使用 NCP 对数据进行预测, 预测结果可用于异常检测。

2.2 动态阈值优化

对于航天器时间序列数据进行预测, 真实值为 y_{real} , 经过 2.1 节中的步骤之后, 得到预测值 y_{pred} , 两者的差值序列为:

$$d = y_{real} - y_{pred} \quad (16)$$

对差值序列进行滑窗处理, 窗口长度和步长均为 L , 对于时间窗口 $d_w = \{d_{t-L+1}, \dots, d_t\}$, 计算窗口内数据的均值和标准差:

$$\mu_t = \frac{1}{L} \sum_{k=t-L+1}^t d_k \quad (17)$$

$$\sigma_t = \sqrt{\frac{1}{L-1} \sum_{k=t-L+1}^t (d_k - \mu_t)^2} \quad (18)$$

其中, d_t 表示时间 t 处的数据点。

计算上下限 UCL_t 和 LCL_t :

$$UCL_t = y_{pred} + \beta_t \cdot \sigma_t \quad (19)$$

$$LCL_t = y_{pred} - \beta_t \cdot \sigma_t \quad (20)$$

其中, β_t 为动态阈值系数。

真实值 $y_{real} = \{y_{t-L+1}, \dots, y_t\}$ 中, 若 $y_i \in [LCL_t, UCL_t]$, 则认为 y_i 是正常值, 超出此范围的值则认为是异常值。在传统异常检测方法中, β 一般取固定值为 1 或 3, 但是取固定阈值用于异常检测无法应对非平稳数据且针对不同的场景泛化能力差。为解决此问题, 使用多目标优化对随机森林模型进行调整, 以找到最佳动态阈值系数 β_t 。

在验证集 $\mathcal{D}_{val} = \{(y_{real}(i), y_{pred}(i))\}_{i=1}^N$ 上, 通过多目标优化最大化异常检测的精确率与召回率, 目标函数设置为:

$$\max_{\beta} (P(\beta), R(\beta)) \quad (21)$$

其中, 精确率 $P(\beta) = \frac{TP}{TP + FP}$, 召回率 $R(\beta) = \frac{TP}{TP + FN}$, 而 TP (真阳性)、 FP (假阳性)、 FN (假阴性) 由阈值系数 β 确定。

采用非支配排序遗传算法求解 Pareto 最优解集, Pareto 前沿解集为 \mathcal{P}^* 。

从 \mathcal{P}^* 中选择最接近理想点 ($P = 1, R = 1$) 的解:

$$\beta^* = \arg \min_{\beta \in \mathcal{P}^*} \sqrt{(1-P(\beta))^2 + (1-R(\beta))^2} \quad (22)$$

对于验证集, 选取一部分数据, 以预测向量作为特征, 将最大 F1 分数对应的最优 β^* 作为标签, 构建训练集, 随机森林模型参数(包括树数量 n_{trees} 、最大深度 d_{max} 、叶子节点最小样本数 s_{min}) 通过多目标优化确定。将最小化 $1 - P(\beta)$ 和 $1 - R(\beta)$ 作为优化目标, 最终得到随机森林模型的最优参数。

本文提出的动态阈值优化方法通过多目标进化算法寻找最优阈值, 从而高效地检测异常。传统固定阈值方法无

法适应遥测数据的非平稳特性, 航天器遥测数据具有伪周期性且包含环境噪声, 数据中存在极端值, 固定阈值方法将会导致高误报率或漏报率。而本文提出的动态阈值优化以最大化 F1 分数为目标, 联合优化精确率与召回率的帕累托前沿, 避免固定阈值因单一指标偏向导致的性能损失, 可以有效应对非平稳数据中的漂移与突发噪声。

2.3 算法评价标准

为了评估不同异常检测方法的检测效果, 根据异常检测结果计算 5 个不同的评价指标, 评价指标包括准确率 (accuracy, ACC)、召回率 (recall, REC)、精确率 (precision, PRE)、F1 分数 (f1 score, F1) 和曲线下面积 (area under the curve, AUC)。

指标的计算方法如表 1 所示, 其中的 TP 、 TN 、 FP 和 FN 分别表示异常样本预测为异常、正常样本预测为正常、异常样本预测为正常和正常样本预测为异常的样本数量。

表 1 异常检测方法评价指标

Table 1 Evaluation metrics for anomaly detection methods

指标名称	计算公式
准确率	$ACC = \frac{TP + TN}{TP + TN + FP + FN}$
精确率	$PRE = \frac{TP}{TP + FN}$
召回率	$REC = \frac{TP}{TP + FP}$
F1 分数	$F1 = \frac{2REC \cdot PRE}{REC + PRE}$
曲线下面积	$AUC = \int_0^1 REC[FPR(u)]^{-1} du$

图 1 所示为本文所提异常检测方法整体框图, 航天器遥测数据经过滑窗处理之后, 经过堆叠自编码器进行降维, 进而使用 NCP 模型进行预测, 结合动态阈值优化寻找最优阈值, 从而进行异常检测。

3 仿真数据实验及结果分析

3.1 仿真数据集

本实验中所用到的数据来源于航天器半实物仿真模型的电源系统, 其结构如图 2 所示。航天器电源系统作为航天器在轨运行的核心保障单元之一, 其可靠性直接关系到航天任务是否能成功执行。输出电压是电源系统能量转换与分配的关键表征参数, 因此通过对输出电压时序数据的实时监测, 可有效获取整个电源系统的工作状态。实验中所用到的数据为航天器仿真模型电源系统不同位置的 6 个电池组的输出电压, 每个参数均包含 27 000 个数据点。

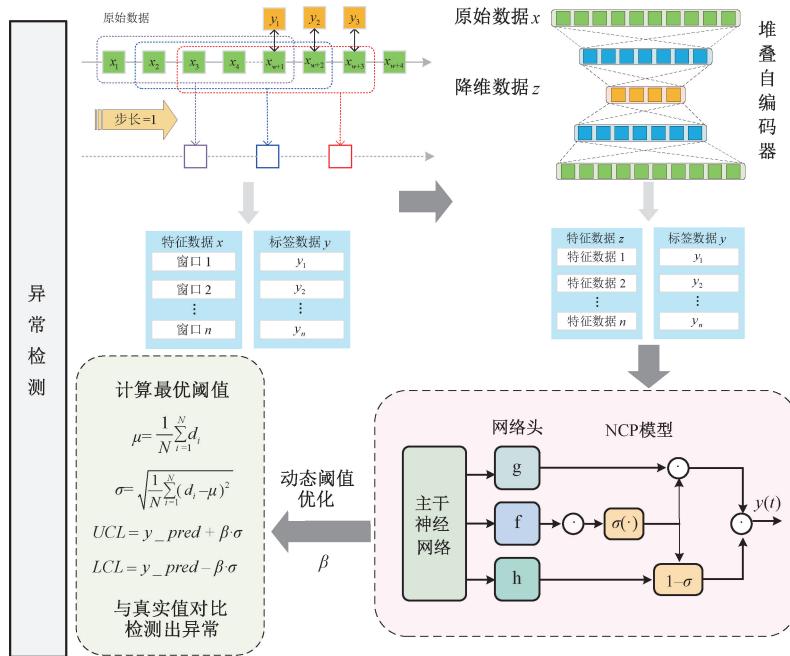


图 1 所提异常检测方法框图

Fig. 1 Block diagram of the proposed anomaly detection method

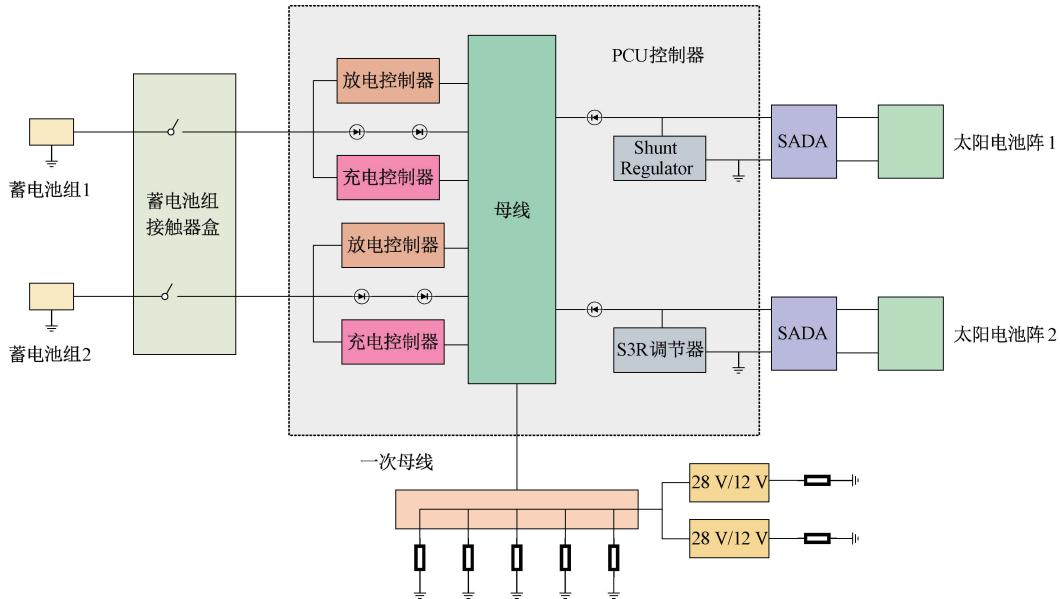


图 2 航天器半实物仿真模型电源系统结构图

Fig. 2 Structure diagram of the power system in the hardware-in-the-loop simulation model for spacecraft

由于航天器异常数据的稀缺性,为了获得足够的实验数据,因此向数据集中植入 4 种不同类型的异常,4 种异常的定义在 1.1 节中已给出,且只向 6 个不同的输出电压参数的其中一个植入异常。本文中训练集全部采用正常数据,植入的异常数据全部在验证集和测试集中。植入 4 种异常的数据与正常数据的对比图如图 3 所示。

对于 4 种不同类型的异常,其植入位置与程度如

表 2 所示,其中的异常程度的参数的含义在 1.1 节中已给出。

航天器遥测数据在采集时,会受到外界环境因素的干扰,从而导致数据中出现噪声,这些噪声会影响异常检测的效果。为了模拟真实情况并测试异常检测方法对于含噪声数据的鲁棒性,在植入异常的基础上,对所有数据植入 40 dB 的噪声。

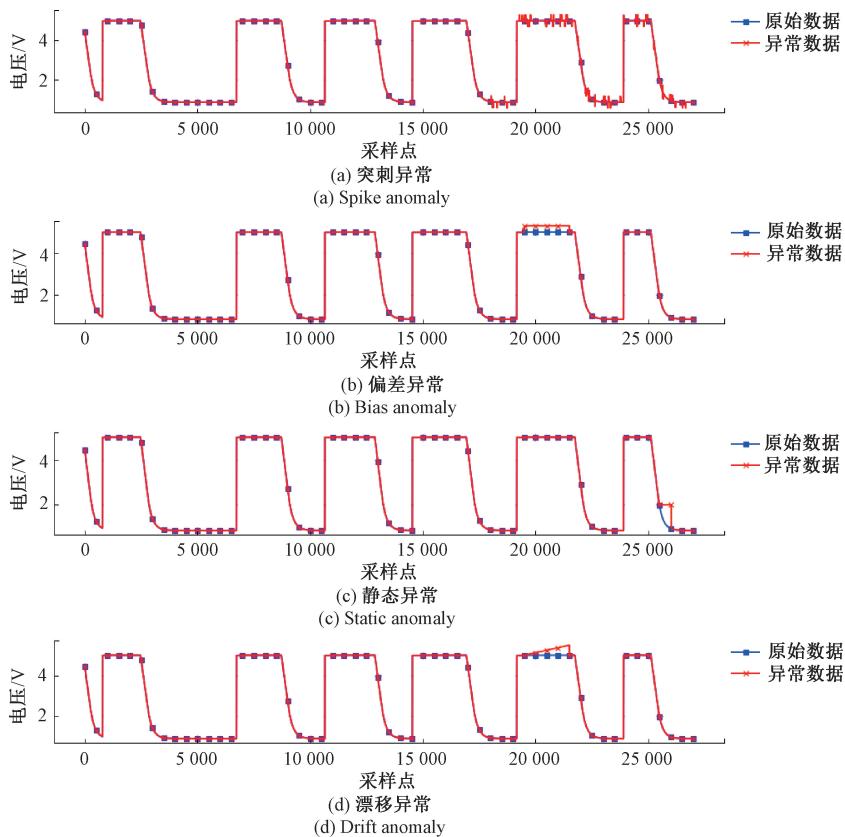


图 3 正常数据与植入异常数据

Fig. 3 Normal data and injected anomalous data

表 2 异常类型与植入参数

Table 2 Anomaly types and injection parameters

异常类型	植入位置	异常程度参数
突刺异常	随机单点	$\alpha = 0.5$
偏差异常	[19 500, 21 500]	$\alpha = 0.5$
静态异常	[25 500, 26 020]	$\alpha = 2$
漂移异常	[19 500, 21 500]	$k = 0.5$

3.2 仿真数据异常检测实验

初始训练集的每个样本的特征为 20 个时间点, 标签为 1 个时间点, 将特征作为输入, 使用堆叠自编码器进行处理, 得到对应的低维向量。堆叠自编码器的结构如表 3 所示, 编码器通过两次非线性映射将 20 维输入压缩至 10 维特征空间, 解码器逆向重建原始维度, 网络训练采用均方误差损失函数与 Adam 优化器。

将低维向量作为新的特征, 标签保持不变, 构成新的训练集, 使用新的训练集对 NCP 进行训练。使用验证集对随机森林模型进行参数优化, 随机森林模型可以根据测试集得到对应的最优阈值, 从而检测出异常, 具体的方法在 2.2 节中已给出。

漂移异常的检测结果如图 4 所示, 正常数据与异常数据的对比图如图 4(a)所示, 其中阴影部分的数据为异常数

表 3 堆叠自编码器网络结构

Table 3 Stacked autoencoder network architecture

网络层	线性变换	激活函数	输出维度
编码器 1 层	20→15	ReLU	15
编码器 2 层	15→10	ReLU	15
解码器 1 层	10→15	ReLU	15
解码器 2 层	15→20	Sigmoid	20

据, 其余部分为正常数据。针对异常数据的检测结果如图 4(b)所示, [400, 600] 区间的局部放大图如图 4(c)所示。

为了证明本文所提方法的有效性, 选取两个常用的深度学习方法 LSTM (long short-term memory) 和 Transformer 作为对比。此外, 选取一个先进的深度学习模型 TFT (temporal fusion transformer) 作为对比, 此模型由 Lim 等^[23] 提出, 是专为多变量时间序列预测而设计, 该模型结合了多头注意力机制和门控残差网络, 可以高效处理复杂的多变量时间序列数据, 还可用于异常检测实验。上述 3 种对比方法均为时间序列预测方法, 预测完成之后, 取阈值系数 $\beta = 1$ 进行异常检测。不同异常的检测的结果如表 4~7 所示。

以漂移异常为例, 由表 7 可以看出, LSTM 和 Transformer 两种方法的召回率较低, 导致其 F1 分数远低

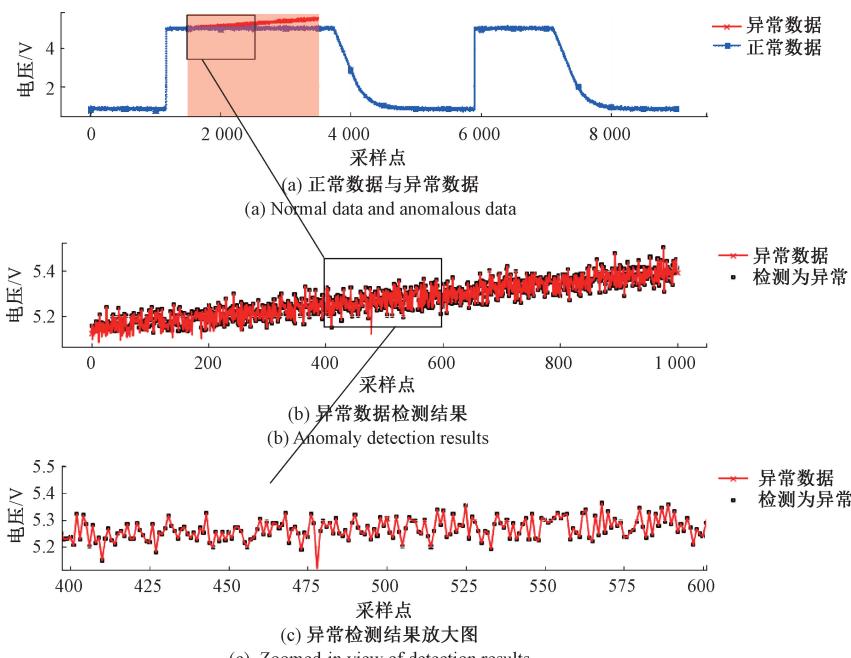


图4 漂移异常检测结果图

Fig. 4 Drift anomaly detection results

表4 突刺异常检测结果

Table 4 Spike anomaly detection results

方法名称	ACC	REC	PRE	F1	AUC
LSTM	0.727	0.020	0.850	0.040	0.788
Transformer	0.564	0.014	0.917	0.027	0.739
TFT	0.973	0.191	0.933	0.317	0.953
所提方法	0.996	0.625	1.000	0.769	0.998

表5 偏差异常检测结果

Table 5 Bias anomaly detection results

方法名称	ACC	REC	PRE	F1	AUC
LSTM	0.757	0.473	0.808	0.597	0.775
Transformer	0.700	0.418	0.904	0.572	0.772
TFT	0.989	0.958	0.995	0.976	0.991
所提方法	0.995	0.977	1.000	0.989	0.997

表6 静态异常检测结果

Table 6 Static anomaly detection results

方法名称	ACC	REC	PRE	F1	AUC
LSTM	0.917	0.513	0.900	0.654	0.924
Transformer	0.692	0.125	0.719	0.212	0.705
TFT	0.937	0.471	0.796	0.592	0.871
所提方法	0.985	0.843	0.917	0.878	0.953

于本文所提方法,因此这两种方法检测效果不佳。而 TFT 的检测召回率和精确率均远高于前两种方法,与本文所提方法进行对比,本文所提方法的检测召回率和 F1 分数分别高了 15.7% 和 8.8%,精确率相同,对于其他指标,本文

表7 漂移异常检测结果

Table 7 Drift anomaly detection results

方法名称	ACC	REC	PRE	F1	AUC
LSTM	0.710	0.335	0.310	0.322	0.567
Transformer	0.722	0.407	0.550	0.468	0.661
TFT	0.943	0.804	0.985	0.885	0.958
所提方法	0.973	0.961	0.985	0.973	0.987

所提方法也都领先于对比方法。对于突刺异常、偏差异常和静态异常,本文所提方法的检测效果也均优于其他对比方法。

为了研究不同方法的效率,记录四种方法的训练时间及测试时间,如表 8 所示。在实际进行航天器异常检测时,是使用已经训练好的模型对新数据直接进行预测,进而进行异常检测,所以对于异常检测方法的效率要求主要在于测试时间,而本文所提方法测试时间与对比方法接近,均能满足实际异常检测的要求。

表8 不同方法训练与测试时间

Table 8 Training and testing time of different methods s

方法名称	训练时间	测试时间
LSTM	176.93	1.65
Transformer	192.60	1.10
TFT	761.70	2.73
所提方法	287.85	1.22

4 卫星数据实验及结果分析

4.1 土壤水分主被动探测卫星数据集

本实验中所用到的数据来源于 NASA 喷气推进实验室公开提供的数据集,此数据集中包含土壤水分主被动探测卫星(soil moisture active passive, SMAP)的数据,且数据集中含有异常数据,有关此数据集的详细信息在文献[24]中。

数据集中包含多个子数据集,选取其中的 E-2 子数据集进行实验,其中的数据为时间序列数据,且都经过匿名化和归一化处理。E-2 子数据集中有 8 532 个时间点的数据,其中异常的点分布在[5 598, 6 995]范围内。数据集中含有 25 个通道的数据,但是只有第 1 个通道的数据为原始数据,因此只选取第 1 个通道的数据进行实验,为适应 3.1 节中各个异常检测模型,将第 1 个通道的数据进行变分模态分解,得到多个子信号数据。将原始数据与 5 个子信号数据组合成为多通道时间序列数据,数据维度与 3.1 节中相同。选取 E-2 子数据集中的部分数据进行实验,由于此数据均为真实数据,因此不再植入异常和噪声,其他处理方式与 3.1 节中相同。E-2 子数据集的数据如图 5 所示。

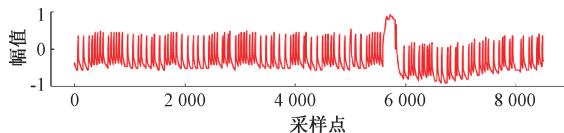


图 5 土壤水分主被动探测卫星 E-2 子数据集数据

Fig. 5 SMAP-E2 sub-dataset of soil moisture active-passive satellite data

4.2 卫星数据集异常检测实验

本实验选取的对比方法与 3.1 节中相同,异常检测结果如表 9 所示。

表 9 卫星数据集异常检测结果

Table 9 Anomaly detection results for satellite dataset

方法名称	ACC	REC	PRE	F1	AUC
LSTM	0.895	0.253	0.927	0.397	0.910
Transformer	0.906	0.271	0.899	0.417	0.902
TFT	0.943	0.379	0.812	0.517	0.902
所提方法	0.994	0.890	0.968	0.927	0.982

由表 9 可知,本文所提方法检测结果的精确率比 LSTM、Transformer 和 TFT 分别高了 4.1%、3.9% 和 15.6%,而 F1 分数分别高了 53.0%、51.0% 和 41.0%,而其他检测指标也均领先于对比方法。实验结果证明,本文所提方法的异常检测效果较好,为航天器的异常检测提供了一种有效的解决方案。

5 结论

航天器异常检测是保障其稳定运行的核心技术,传统

异常检测方法设定固定阈值用于检测异常,难以应对非平稳性数据与噪声干扰。针对这一挑战,本文提出一种基于表示学习与动态阈值优化的异常检测方法,为航天器异常检测提供一种新的解决方案。本文所提方法首先通过堆叠自编码器对原始时序数据进行特征压缩;其次,使用 NCP 模型对遥测数据进行预测;最后,使用多目标优化驱动的动态阈值优化,计算最优阈值。本文在两个航天器数据集上进行了实验,实验结果表明,本文所提方法在针对航天器遥测数据的异常检测中表现优异,较对比方法显著提升异常检测的综合性能,表现出良好的鲁棒性。

在未来的研究中,可以联合建模时序与空间特征,充分挖掘多源数据的互补性,提高检测效果。

参考文献

- [1] 刘腾飞. 基于动态阈值的航天器遥测数据异常检测[D]. 西安: 西安工业大学, 2024: 3-12.
- [2] LIU T F. Dynamic threshold-based anomaly detection for spacecraft telemetry data [D]. Xi'an: Xi'an Technological University, 2024: 3-12.
- [3] 张金垒, 庞景月, 卢晓伟, 等. Feen-LSTM: 一种优化的多遥测参数在线无监督异常检测方法[J]. 仪器仪表学报, 2025, 46(1): 1-11.
- [4] ZHANG J L, PANG J Y, LU X W, et al. Feen-LSTM: An optimized online unsupervised anomaly detection method for multi-telemetry parameters[J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 1-11.
- [5] PILASTRE B, BOUSSOUF L, D'ESCRIVAN S, et al. Anomaly detection in mixed telemetry data using a sparse representation and dictionary learning [J]. Signal Processing, 2020, 168: 107320.
- [6] YANG K, WANG Y, HAN X, et al. Unsupervised anomaly detection for time series data of spacecraft using multi-task learning[J]. Applied Sciences, 2022, 12(13): 6296.
- [7] 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.
- [8] HE J H, CHENG ZH J, GUO B. Telemetry anomaly detection method based on joint dictionary learning and OCSVM[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(13): 327931.
- [9] YI X J, HUANG P ZH, CHE SH J. Application of knowledge graph technology with integrated feature data in spacecraft anomaly detection [J]. Applied Sciences, 2023, 13(19): 10905.
- [10] LIU L, TIAN L, KANG ZH, et al. Spacecraft anomaly detection with attention temporal convolution networks [J]. Neural Computing and Applications,

- 2023, 35(13): 9753-9761.
- [8] LI X, ZHANG T, LIU Y. Detection of voltage anomalies in spacecraft storage batteries based on a deep belief network[J]. Sensors, 2019, 19(21): 4702.
- [9] YU B, YU Y, XU J, et al. MAG: A novel approach for effective anomaly detection in spacecraft telemetry data[J]. IEEE Transactions on Industrial Informatics, 2023, 20(3): 3891-3899.
- [10] WANG Y, ZHANG T, HUI J J, et al. An anomaly detection method for spacecraft solar arrays based on the ILS-SVM model [J]. Journal of Systems Engineering and Electronics, 2023, 34(2): 515-529.
- [11] SU J, LONG Y, QIU X F, et al. Anomaly detection of single sensors using OCSVM_KNN[C]. Big Data Computing and Communications: First International Conference, 2015: 217-230.
- [12] 王婵,王慧泉,金仲和.皮纳卫星遥测数据异常检测聚类分析方法[J].哈尔滨工业大学学报,2018,50(4): 110-116.
- WANG CH, WANG H Q, JIN ZH H. Pico-satellite telemetry anomaly detection through clustering [J]. Journal of Harbin Institute of Technology, 2018, 50(4): 110-116.
- [13] LIU L, TIAN L, KANG ZH, et al. Spacecraft anomaly detection with attention temporal convolution networks[J]. Neural Computing and Applications, 2023, 35(13): 9753-9761.
- [14] 王永康,艾山·吾买尔,顾亚东,等. TransREF: 一种改进的基于邻域信息的知识表示模型[J]. 电子测量技术, 2023, 46(21): 7-15.
- WANG Y K, AISHAN W M ER, GU Y D, et al. TransREF: An improved knowledge representation model based on neighborhood information [J]. Electronic Measurement Technology, 2023, 46(21): 7-15.
- [15] 赵伟豪. 基于序列数据表示学习的用户偏好建模方法研究[D]. 北京:中国科学技术大学, 2024: 1-21.
- ZHAO W H. User preference modeling methods via sequential data representation learning [D]. Beijing: University of Science and Technology of China, 2024: 1-21.
- [16] WANG B, LIU D, PENG Y, et al. Multivariate regression-based fault detection and recovery of UAV flight data[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(6): 3527-3537.
- [17] WANG B K, LIU D T, PENG X Y, et al. Data-driven anomaly detection of UAV based on multimodal regression model [C]. 2019 IEEE International Instrumentation and Measurement Technology Conference(I2MTC), 2019: 1-6.
- [18] WANG X, WANG CH. Time series data cleaning with regular and irregular time intervals[J]. ArXiv preprint arXiv:2004.08284, 2020.
- [19] XU ZH P, CHENG ZH J, GUO B. A hybrid data-driven framework for satellite telemetry data anomaly detection [J]. Acta Astronautica, 2023, 205: 281-294.
- [20] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representations by error propagation[J]. Readings in Cognitive Science, 1988, 323(6088):399-421.
- [21] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [22] LECHNER M, HASANI R, AMINI A, et al. Neural circuit policies enabling auditable autonomy [J]. Nature Machine Intelligence, 2020, 2(10): 642-652.
- [23] LIM B, ARIK S Ö, LOEFF N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting [J]. International Journal of Forecasting, 2021, 37(4): 1748-1764.
- [24] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding [C]. 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018: 387-395.

作者简介

苗强(通信作者),教授,主要研究方向为重大装备故障诊断、健康评估以及可靠性研究。

E-mail: mqiang@scu.edu.cn