

DOI: 10.19650/j.cnki.cjsi.J2514518

基于时空联合聚类的航天器异常检测算法*

郑茗畅¹, 于劲松¹, 周金淦¹, 赵春州², 彭宇³

(1. 北京航空航天大学自动化科学与电气工程学院 北京 100191; 2. 北京航空航天大学仪器科学与光电工程学院 北京 100191; 3. 北京航天自动控制研究所 北京 100854)

摘要: 航天器在轨运行具有长期自主、环境复杂等特点, 其异常检测需在先验知识不完备与资源配置有限的双重约束下满足高实时性要求, 因此通常采用轻量化无监督异常检测算法, 基于距离的方法是其中常用的一种。但在面对高维复杂遥测数据进行异常检测任务时, 传统基于距离的方法因无法捕捉参数时空耦合性蕴含的丰富异常特征导致检测性能显著下降。针对传统基于距离的方法存在的上述缺陷, 提出一种时空联合聚类框架。该框架在保留传统基于距离方法轻量化优势的基础上, 通过定义一种新型时空距离度量代替传统距离定义, 动态感知并量化参数在演化过程中的时序依赖关系和不同参数间的耦合关系。为验证所提出的时空联合聚类框架对传统基于距离方法的改进效果, 以归纳监视系统(IMS)算法这一经典基于距离的方法为例, 基于时空联合聚类框架对其进行针对性改进, 并采用航天器电源系统仿真数据和真实运行数据对改进方法进行了应用验证。结果表明, 改进方法在满足航天器异常检测实时性需求的前提下, 检测平衡准确率较传统方法在两数据集上分别提升了 20.34% 和 5.87%, 对正常和异常数据均能够实现正确判别, 为基于距离的方法应用于航天器复杂时空耦合异常的检测提供了理论支撑与技术路径。

关键词: 航天器; 异常检测; 时空距离; 耦合性挖掘; 归纳监视系统

中图分类号: TH707 **文献标识码:** A **国家标准学科分类代码:** 460.40

Anomaly detection algorithm of spacecraft based on spatio-temporal joint clustering

Zheng Mingchang¹, Yu Jinsong¹, Zhou Jinhan¹, Zhao Chunzhou², Peng Yu³

(1. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China;
2. School of Instrumentation and Optoelectronic Engineering, Beihang University, Beijing 100191, China;
3. Beijing Aerospace Automatic Control Institute, Beijing 100854, China)

Abstract: Spacecraft in-orbit operations exhibit characteristics such as prolonged autonomous functioning and complex environmental conditions. Anomaly detection in such situations must satisfy stringent real-time requirements under dual constraints of incomplete prior knowledge and limited resource allocation. Consequently, lightweight unsupervised anomaly detection algorithms are commonly employed, with distance-based methods being a prevalent approach. However, when addressing anomaly detection tasks involving high-dimensional, complex telemetry data, traditional distance-based methods suffer significant performance degradation, which arises from their inability to capture the rich anomaly features inherent in the spatio-temporal coupling of parameters. To address these limitations, a spatio-temporal joint clustering framework is proposed. Building upon the lightweight advantages of conventional distance-based approaches, this framework introduces a novel spatio-temporal distance metric. This metric dynamically perceives and quantifies the temporal dependencies within parameter evolution and the coupling relationships between different parameters. To demonstrate the effectiveness of the proposed framework, the classical inductive monitoring system (IMS) algorithm is enhanced by incorporating the proposed spatio-temporal distance metric. The enhanced algorithm is then validated using both simulated and real operational data from spacecraft power systems. Results demonstrate that while meeting the real-time requirements for spacecraft anomaly detection, the enhanced

收稿日期: 2025-09-20 Received Date: 2025-09-20

* 基金项目: 国家重点研发计划(2022YFB3304600)、国家自然科学基金(52375074)项目资助

algorithm achieves a detection balance accuracy improvement of 20.34% and 5.87% over traditional methods on two datasets respectively. The enhanced algorithm effectively distinguishes between normal and abnormal data, providing both substantial theoretical support and a technical pathway for applying distance-based methods to detect complex spatio-temporally coupled anomalies in spacecraft.

Keywords: spacecraft; anomaly detection; spatio-temporal distance; coupling-mining; inductive monitoring system

0 引言

航天器在轨安全稳定运行面临显著的故障风险^[1],这一风险主要有两方面原因:一方面,系统规模与复杂度的持续攀升是导致故障可能增加的内部因素^[2];另一方面,航天器所处的极端太空环境构成了严峻的外部威胁^[3]。在此背景下,实施及时且有效的异常检测,以实现故障早期预警,已成为保障航天器在轨安全稳定运行的关键环节^[4]。

特殊的运行环境决定了航天器异常检测与常规装备系统的异常检测不同,面临3方面挑战:

1) 检测结果不实时:现有的航天器异常检测基于在轨卫星下传的遥测数据,数据下传的延时和丢包导致异常检测结果无法实时给出,无法提前采取补救措施并最终导致航天器故障^[5]。

2) 先验知识不完备:为确保航天器在轨安全稳定运行,通常采用高可靠、高冗余设计,这导致航天器真实故障样本稀缺,无法支撑传统智能算法训练,难以应对未知的故障情况^[6]。

3) 资源配置不充分:重量、体积、成本等客观约束限制了异常检测算法的可用资源,导致以自编码器^[7](autoencoder, AE)为代表的智能算法难以应用于航天器在轨异常检测^[8]。

鉴于上述在资源配置与先验知识上的双重约束及航天器异常检测高实时性的客观需求,轻量化的无监督异常检测算法成为了解决航天器在轨检测问题的必然选择。当前轻量化无监督异常检测算法主要包括基于回归的方法、基于距离的方法和基于关联关系的方法。其中基于回归的方法通过建立回归模型对参数进行预测,使用预测值与真实值之间的差异来定义异常^[9];但这种时间序列预测模型对噪声敏感,会因真实数据中的常见噪声导致算法泛化能力变差,并增加误报概率^[10],因此不适用于航天器异常检测。

基于距离的方法通过计算待测数据点与其他点之间的距离来确定待测数据点是否异常^[11]。美国航天局提出归纳监视系统(inductive monitoring system, IMS)算法,采用增量自主学习策略,在超参数配置、在线模型更新等方面具有优越性,并在国际空间站、哥伦比亚航天飞机等典型航天器系统上进行了实际应用^[12]。胡健等^[13]通过利用K均值(K-means)聚类算法计算遥测数

据的聚类中心,然后考虑噪声特性利用动态变步长计算包络上下界,通过计算待测数据与包络上下界的距离实现对遥测缓变参数异常的快速检测。Cui等^[14]采用加速动态时间规整方法计算时间序列之间的距离,并采用K最近邻(K-nearest neighbor, KNN)算法进行分类,实现对卫星时间序列的快速异常检测。Bollam等^[15]采用欧氏距离、余弦距离等距离指标计算时间序列之间的距离,并采用孤立森林(isolation forest, iForest)算法进行异常检测,在航天器温度传感器数据上进行了验证。然而,随着航天器结构功能的快速演进,遥测参数规模呈爆发式增长,参数间的时变特性日益复杂,航天器运行状态综合反映在不同时空的遥测数据中^[16]。传统基于距离的方法在应对此类高维复杂场景时逐渐显露出“时空感知盲区”:其通常仅依据单一时刻的数据点距离来判别异常,既无法捕捉参数在演化过程中的时序依赖关系(时间维度),也难以量化不同参数间强弱各异的耦合机制(空间维度)^[17]。这种对“时空关联特征”的忽视,导致算法无法充分挖掘潜藏的故障征兆,造成检测性能显著下降。

基于关联关系的方法对数据中的关联关系进行挖掘,不符合正常关联关系的待测数据被定义为异常^[18]。宋华婷等^[19]将卫星参数伪周期时间序列进行周期子序列划分,对周期子序列基于符号聚合近似算法和 n 元语法模型提取其潜在特征并符号化表示,基于快速动态时间规整算法计算符号化表示后周期子序列间相似性,如果待检测周期子序列与标准周期子序列相似性超过阈值上限则定义为异常。丛安东^[20]使用灰色理论和最大信息系数度量数据关联度,使用关联度大的数据结合符号动力学以及统计学知识,通过对数据稳定性的判断将数据符号向量表示,使用频繁模式树算法挖掘待测数据频繁模式,与正常数据的频繁模式进行对比,实现遥测数据异常检测。杨甲森等^[21]定义遥测数据相关性并对单维度遥测数据的6种领域相关性进行建模和向量表示,采用相关性知识发现算法提取遥测数据中的相关性特征,与正常数据提取的相关性特征进行对比,二者不一致则确定为异常。然而,随着航天器结构功能的快速演进,参数关联关系日益复杂,在进行关联关系挖掘时挖掘难度和成本较大^[22];此外,在轨检测时需要将待测数据的关联关系与正常模式的关联关系进行对比,高维关联关系会导致算力需求超过限制,无法满足在轨检测场景的算法轻量化需求。

因此,针对传统基于距离的轻量无监督异常检测方法因无法捕捉参数时空耦合性蕴含的丰富异常特征导致检测性能显著下降的问题,本文提出了一种时空联合聚类框架。该框架在保留传统基于距离方法轻量化优势的基础上,通过定义一种新型时空距离度量,动态感知并量化参数间的耦合关系与时序依赖。在此基础上,对IMS这一经典算法进行了改进,从而在不显著增加计算负担的前提下,实现了航天器异常检测在检测平衡准确率等关键指标上的显著提升,对正常和异常数据均能够实现正确判别,为基于距离的方法应用于航天器复杂时空耦合异常的检测提供了理论支撑与技术路径。

1 遥测参数时空耦合性的定义与形式化

1.1 遥测参数时空耦合性的定义

遥测参数空间维度上的耦合性指的是不同遥测参数在取值上存在的强弱差异的耦合关系。作为典型的复杂系统,航天器所包含的通信、热控制、轨道控制、姿态控制、电源管理等分系统之间和分系统各零部件之间均存在着复杂的信息交互和功能依赖关系;同时航天器各分系统的工作均受到空间环境、飞行事件、控制指令等因素影响。这些都决定了反映航天器运行状态的遥测参数之间存在必然的耦合关系,即遥测参数空间维度上的耦合性。

遥测参数时间维度上的耦合性指的是同一遥测参数在当前时间窗口与历史时间窗口中表现出的时序相关性。例如,航天器规律运行时,姿态控制、轨道控制、电源等分系统的遥测参数会表现出一定的周期特性,这种周期特性是遥测参数时间维度上的耦合性的一种体现;此外,同一遥测参数在不同时刻发生同类异常时会表现出一定的相似性,这种相似性也是遥测参数时间维度上的耦合性的一种体现^[23]。

1.2 遥测参数时空耦合性的形式化

本文将遥测参数时空耦合性的相关概念形式化,以便于对所提时空联合聚类框架进行阐述。记待处理的单个滑动时间窗口内遥测数据为 $\mathbf{X} \in \mathbf{R}^{N \times M}$, 其中 N 为窗口长度, M 为单帧所包含的参数规模, 则有以下8种定义:

定义1:窗口向量化结果 $\mathbf{I} \in \mathbf{R}^{(N \times M)}$, $\mathbf{I}$ 包含 $(N \times M)$ 个元素, 滑动时间窗口中各帧数据按照时间先后进行拼接得到的结果向量。

定义2:同步性,定义1中结果向量的分量在同一簇 C_i 内,称这些分量具有同步性。同步性包括不同遥测参数间的同步性和同一遥测参数在时间窗口内不同帧的同步性。具有同步性的分量组合即该簇耦合组合 $\mathbf{A}$, 耦合组合所包含的元素个数即该簇耦合维度。

$$\begin{aligned} \mathbf{A}_i^{\text{train}} &= \{j \in \{1, \dots, (N \times M)\} \mid \mathbf{D}_i^{(j)}(\mathbf{I}, \mathbf{C}) = 0\} \quad (1) \\ \mathbf{A}_i^{\text{test}} &= \{j \in \{1, \dots, (N \times M)\} \mid \mathbf{D}_i^{(j)}(\mathbf{I}, \mathbf{C}) < T_{\text{th}}\} \quad (2) \end{aligned}$$

式中: $\mathbf{A}_i^{\text{train}}$ 与 $\mathbf{A}_i^{\text{test}}$ 分别为簇 C_i 对应的训练和检测阶段耦合组合; T_{th} 为检测阶段正常数据超限阈值; $\mathbf{C}$ 是训练数据划分形成的簇群; $\mathbf{D}_i^{(j)}(\mathbf{I}, \mathbf{C})$ 是定义1中结果向量各分量距各簇上下限的超限距离组成的矩阵第 i 行第 j 个分量。

定义3:先验时空最小耦合维度 $N_R \in \mathbf{N}$, 训练阶段为样本具有频繁同步性的最小耦合维度预设的估计值。

定义4:分量同步性矩阵 $\hat{\mathbf{R}} \in \mathbf{R}^{(N \times M) \times (N \times M)}$, 聚簇时基于分量同步性动态估计分量时空耦合性所得经验矩阵, 矩阵的第 i 行第 j 列代表分量 i 相对于分量 j 存在的耦合程度。

定义5:参数耦合性矩阵 $\hat{\mathbf{R}}_{\text{last}} \in \mathbf{R}^{M \times M}$, 将分量同步性矩阵重构为四维张量后, 提取窗口最后一个时间步各参数的时空耦合维度构成的矩阵。四维张量的形式为 $[M, N, M, N]$, 提取时取第4个维度最后一个时间步以反映当前时刻的参数时空耦合性, 结果沿第2个维度求和, 即可得到参数耦合性矩阵。矩阵的第 i 行第 i 列代表参数 i 在窗口内的时间耦合维度, 矩阵的第 i 行第 j 列代表参数 i 在窗口内与参数 j 的空间耦合维度。

定义6:后验空间最小耦合维度 $N_{R, \text{space}} \in \mathbf{R}^M$, 统计各参数具有空间耦合性的参数数目所得估计值。由参数耦合性矩阵得到:

$$N_{R, \text{space}}^{(j)} = \sum_{j^*} \hat{\mathbf{R}}_{\text{last}_{j^* j}} - \hat{\mathbf{R}}_{\text{last}_{j j}} \quad (3)$$

该矢量即检测阶段参数的空间最小耦合维度。

定义7:后验时间最小耦合维度 $N_{R, \text{time}} \in \mathbf{R}^M$, 统计各参数窗口内具有时间耦合性的帧数目所得估计值。由参数耦合性矩阵得到:

$$N_{R, \text{time}}^{(j)} = \hat{\mathbf{R}}_{\text{last}_{j j}} \quad (4)$$

该矢量即检测阶段参数的时间最小耦合维度。

定义8:距离矢量 $\mathbf{d}(\mathbf{I}, \mathbf{C}) \in \mathbf{R}^{(N \times M)}$, $\mathbf{d}(\mathbf{I}, \mathbf{C})$ 包含 $(N \times M)$ 个元素, 逐分量根据先验时空最小耦合维度(训练阶段)或后验空间最小耦合维度和后验时间最小耦合维度(检测阶段)滤除距离矩阵 $\mathbf{D}(\mathbf{I}, \mathbf{C})$ 中耦合维度不满足的簇行后, 各列最小值组成的距离矢量。

2 传统基于距离的异常检测方法及其不足:以IMS为例

在航天器异常检测领域,基于距离的无监督方法有多种实现方式。其中,归纳监视系统(IMS)算法是一种广泛应用的代表性方法。

IMS算法通过增量式学习,将正常数据在特征空间中划分为若干个超矩形区域(称为“簇”)。这个过程在

形式上与聚类算法有相似之处,但其核心是构建数据的边界描述,而非寻找数据中心的聚合。在检测阶段,算法计算待测点到最近“簇”边界的距离(常用切比雪夫距离)来判断其是否异常。该距离定义可形式化描述为:

$$d(\mathbf{X}, \mathbf{C}) = \min_i \|\mathbf{D}_i(\mathbf{X}, \mathbf{C})\|_{\infty} \quad (5)$$

式中:待处理数据 $\mathbf{X} \in \mathbf{R}^M$, 为单帧遥测数据。

该距离定义的输入数据为单帧遥测数据,不包含遥测参数时间维度上的耦合性信息。同时,该距离定义默认数据所有参数同步变化,未考虑遥测参数具有的空间维度上的耦合性^[24]。随着航天器结构功能的快速演进,遥测参数规模呈爆发式增长,参数间的时变特性日益复杂,航天器运行状态综合反映在不同时空的遥测数据中,该点-簇群距离定义对参数时空耦合性特征的忽视,导致传统 IMS 算法无法充分挖掘潜藏的故障征兆,造成检测性能显著下降^[25]。

面对上述问题,传统 IMS 算法亟需得到改进。最为简单直接的方法是将输入数据更改为定义 1 中的滑动窗口向量化结果,在输入中引入遥测参数时间维度上的耦合性信息。然而,该改进策略主要面临 3 个问题:

1) 此改进策略仅停留在输入层面对时间耦合性进行形式化处理,未触及算法核心的距离计算逻辑。其结果是,尽管输入数据包含了时间信息,算法仍缺乏机制来捕捉参数真实的时间维度耦合性信息,最终无法实现检测指标的真正改进;

2) 此改进策略并未修改距离计算逻辑,仍然默认数据所有参数同步变化,未考虑遥测参数具有的空间维度上的耦合性;

3) 此改进策略并未修改距离计算逻辑,导致如果某一帧检测数据存在异常,在传统距离计算逻辑下包含该帧的所有窗口均会被判定为异常,导致异常检测虚警率大幅上升。

由此可见,仅更改输入数据的改进方法并未真正从传统 IMS 算法无法充分挖掘参数时空耦合性特征中潜藏故障征兆的缺陷出发,并不能真正对传统算法进行有效的改进。由上述分析可见,传统 IMS 算法的点-簇群距离定义是算法未考虑参数时空耦合性的集中体现,应针对性优化点-簇群距离定义,考虑参数时空耦合性特征,进而实现 IMS 算法检测性能上的提高。

3 时空联合聚类框架

针对第 2 章所述的传统 IMS 算法无法感知参数时空耦合性的缺陷,本文提出了一个通用的时空联合聚类框架,并利用该框架对传统 IMS 算法进行针对性改进。该框架通过定义一种新的时空距离度量来动态感

知并量化参数的时空耦合性,从而实现算法检测性能上的提高。

3.1 基于时空耦合性评估的时空距离定义

时空联合聚类框架通过采用基于时空耦合性评估的时空距离定义代替传统距离定义,实现对参数时空耦合性的动态感知与量化。算法 1 介绍了基于时空耦合性评估的时空距离计算过程,其中 $|\cdot|$ 代表输入集合的元素个数。

算法 1: 基于时空耦合性评估的时空距离

输入:窗口向量化结果 $\mathbf{I}$, 簇群 $\mathbf{C}$, 空间最小耦合维度 $N_{R, \text{space}}$, 时间最小耦合维度 $N_{R, \text{time}}$

参数:离簇阈值 T_{th}

输出:点-簇群距离 d

- 1) $\mathbf{D} = \mathbf{D}(\mathbf{I}, \mathbf{C})$;
- 2) $\mathbf{d} = [T_{th}, T_{th}, \dots, T_{th}]$; % 初始化距离矢量
- 3) $\mathbf{A}_i = \{j | \mathbf{D}_i^{(j)} < T_{th}\}$; % 计算各簇耦合组合
- 4) for $j = 1:M$
- 5) $\mathbf{A}_{i, \text{time}}^{(j)} = \{k | (\mathbf{D}_i^{(k)} < T_{th}) \cap (k \% j = 0)\}$; % 计算各簇参数的时间耦合组合
- 6) $\mathbf{J} = \{i | (|\mathbf{A}_{i, \text{time}}^{(j)}| > N_{R, \text{time}}^{(j)}) \cap [(|\mathbf{A}_i| - |\mathbf{A}_{i, \text{time}}^{(j)}|) > N_{R, \text{space}}^{(j)}]\}$; % 滤除无效簇
- 7) if $|\mathbf{J}| \neq 0$, then
- 8) $\mathbf{d}^{(j)} = \min_{i \in \mathbf{J}} \mathbf{D}_i^{(j)}$; % 更新参数 j 的分量
- 9) $d = \|\mathbf{d}\|_{\infty}$; % 根据距离矢量计算距离

参数时空耦合性的重要表现为耦合的不同参数或同一参数不同帧存在的频繁同步性。耦合性不强的不同参数或同一参数不同帧并不具备同步性或同步性出现不频繁。根据上述特征,在距离定义中嵌入参数时空耦合性的自主感知机制,是提高算法检测性能的关键。算法首先使用离簇阈值 T_{th} 对距离矢量进行初始化;然后根据定义 2 计算各簇的耦合组合;对于每个参数,根据定义 2 分别计算各簇中该参数对应的时间耦合组合,然后根据空间最小耦合维度和时间最小耦合维度对不满足参数时空耦合性要求的簇进行滤除,根据滤除后的有效簇行对参数对应的距离矢量分量进行更新;最终得到的距离矢量切比雪夫距离为窗口向量化结果 $\mathbf{I}$ 与簇群 $\mathbf{C}$ 的点-簇群距离。

训练阶段,该距离定义的空间最小耦合维度和时间最小耦合维度均设为定义 3 的先验时空最小耦合维度,根据训练数据与簇群的点-簇群距离是否为 0,判断簇群能否完整表征训练数据。

检测阶段,该距离定义的空间最小耦合维度设为定义 6 的后验空间最小耦合维度,时间最小耦合维度设为

定义7的后验时间最小耦合维度,根据待检测数据与簇群的点-簇群距离是否大于离簇阈值,判断待检测数据是否异常。

3.2 改进 IMS 算法的训练机制

训练阶段,算法的主要任务是基于含有大量可挖掘参数时空耦合性信息的高可信数据,实现集约度高的聚“簇”并挖掘高可信的参数耦合性矩阵。

因此,改进 IMS 算法不仅采用基于时空耦合性评估

的时空距离代替传统距离,还通过动态更新的分量同步性矩阵,量化统计不同遥测参数间的同步性和同一遥测参数在时间窗口内不同帧的同步性,从而实现对遥测参数时空耦合性的自主感知。

如图1所示,算法将第1个时间窗口向量化结果设为初始簇群,并以单位阵初始化分量同步性矩阵和参数耦合性矩阵,之后逐窗口载入后续数据,迭代更新簇群和分量同步性矩阵。




图1 改进 IMS 算法的训练机制

Fig. 1 Training mechanism for the improved IMS algorithm

具体而言,在迭代更新过程中,每载入一个窗口的数据,算法即采用基于时空耦合性评估的时空距离代替传统距离,以判断该窗口数据入簇与否。一方面,如果窗口数据未入簇,算法会与传统 IMS 算法一样扩张现有簇群或新建簇^[26];另一方面,在参数时空耦合性自主感知机制下,算法会根据当前窗口数据更新分量同步性矩阵:算

法逐分量寻找当前分量在上下限(或扩张上下限)内且耦合维度最小的有效簇行,将总量为1的增益权重平均分配给该簇行耦合维度中包括分量本身在内的所有耦合分量,从而在当前分量所在的分量同步性矩阵行上更新权重。在迭代更新完成后,算法得到统计性质的分量同步性矩阵。为进一步得到反映遥测参数时空耦合性的参

数耦合性矩阵,基于分量与自身同步性为 1 的性质修正分量同步性矩阵,即:

$$\hat{R}_{j,j}^* = \frac{R_{j,j}^*}{R_{j,j}}$$

(6)

然后根据定义 5 将矩阵重构并提取最后一个时间步各参数的时空耦合维度,得到参数耦合性矩阵。根据定义 6 和 7 计算后验空间最小耦合维度 $N_{R,space}$ 和后验时间最小耦合维度 $N_{R,time}$ 。簇群、后验空间最小耦合维度 $N_{R,space}$ 和后验时间最小耦合维度 $N_{R,time}$ 三者共同组成算法训练的最终模型。

改进的训练机制优势在于使用参数耦合性矩阵实现遥测参数时空耦合性的自主感知。参数耦合性矩阵利用耦合的不同参数及同一参数不同帧在簇中同步出现更为频繁的特征,通过平均分配权重与选择最小耦合维度的方法在迭代过程中凸显耦合性强的参数时空耦合关系,从而得到更适合的后验空间最小耦合维度和后验时间最小耦合维度,支撑后续的检测任务。

3.3 改进 IMS 算法的检测机制

在检测过程中,算法需要利用已挖掘得到的后验空间最小耦合维度和后验时间最小耦合维度,指导算法在各参数维度上完成对待检测数据与现有簇群更适合的距离评估。

如图 2 所示,根据训练阶段得到的簇群、后验空间最小耦合维度 $N_{R,space}$ 和后验时间最小耦合维度 $N_{R,time}$,算法采用基于时空耦合性评估的时空距离计算待检测数据与簇群的距离。进一步,定义距离与检测阈值 T_{th} 的比值(≤ 1)为待检测数据的异常分数。如果异常分数为 0,说明待检测数据在现有簇群范围内,待检测数据完全正常。如果异常分数为 1,说明待检测数据距现有簇群的距离已经大于检测阈值,待检测数据异常。如果异常分数范围在 0 ~ 1,说明待检测数据超过现有簇群范围,但超限距离并未大于检测阈值,待检测数据正处于从正常到异常的变化过程中。




图 2 改进 IMS 算法的检测机制

Fig. 2 Testing mechanism for the improved IMS algorithm

改进的检测机制采用基于时空耦合性评估的时空距离代替传统距离,能够捕捉参数时空耦合性蕴含的丰富异常特征,从而提升算法检测平衡准确率等关键指标。此外,算法通过后验空间最小耦合维度和后验时间最小耦合维度对簇群进行精简,使得算法在提升检测指标的同时,依旧能够符合实际航天器在轨异常检测算法的实时性和轻量化需求。

4 实验验证

4.1 实验设置

为验证提出的基于时空联合聚类框架改进的 IMS 算法在应对航天器复杂时空耦合异常时的应用效果,本文构建了航天器电源系统仿真模型,如图 3 所示。




图 3 航天器电源系统仿真模型

Fig. 3 Simulation model of spacecraft power system

模型模拟了航天器在轨运行时外界环境光照期和地影期交替切换的过程,由太阳电池阵、蓄电池组和电源控制器 3 部分组成:太阳电池阵是电源系统的能源模块,负责在航天器处于光照期时从外部获取光能并将其转化为电能,向蓄电池组充电并为负载供电;蓄电池组是电源系统的储能模块,在航天器处于光照期时进行充电,在航天器处于地影期时为负载供电;电源控制器是电源系统的控制模块,负责控制蓄电池组充放电并分配输出电能给负载^[27]。实验通过向模型内部性能参数(充电电流、电阻)注入数值层面的退化曲线,从而模拟复杂时空耦合异常的发生,注入前后的信号时序如图 4 和 5 所示。

此外,实验还采用航天器电源系统的真实运行数据^[28]进行实验验证。在排序、采样、拼接等预处理环节后,得到同一连续时段下的 27 924 帧数据,后按 3:1 的比例均匀划分为训练集和测试集,二者无时间重合且均覆盖完整过程。在测试集中,仿照航天器电源系统退化仿真数据,实验对航天器电源系统发生的复杂时空耦合异




图 4 注入前仿真数据的信号时序

Fig. 4 Signal timing of pre-injection simulation data




图 5 注入后仿真数据的信号时序

Fig. 5 Signal timing of the injected simulation data

常进行模拟,共注入分散在 8 个连续时段下的 1 600 帧异常。

4.2 验证策略

为突出基于时空联合聚类框架改进的 IMS 算法相较于传统算法的优势,针对传统算法在应对航天器复杂时空耦合异常时检测性能显著下降的问题,采取使用效率和检测精度两方面进行评估。

使用效率通过每帧训练用时和每帧检测用时进行衡量,每帧训练用时体现算法从获取历史数据到正式上线所需时间,每帧检测用时体现算法检测实时性。检测精度包括精确率 P 、召回率 R 、准确率 Acc 、 $F1$ 分数和平衡准确率 $Bacc$ 这 5 个指标,分别反映算法的漏检概率、虚警概率、推理错误概率、减少漏检和降低虚警之间的平衡能力、类别不平衡下的推理鲁棒性:

$$P = \frac{TP}{TP + FP} \tag{7}$$

$$R = \frac{TP}{TP + FN} \tag{8}$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \tag{9}$$

$$F1 = 2 \times \frac{P \times R}{P + R} \tag{10}$$

$$Bacc = \frac{1}{2} \times \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \tag{11}$$

式中: TP 为标签与检测结果均正常的样本数; TN 为标签与检测结果均异常的样本数; FP 为标签异常但检测结果正常的样本数; FN 为标签正常但检测结果异常的样本数。

4.3 结果分析

1) 对比实验

为了证明本文所提时空联合聚类框架改进的有效性,实验分别通过传统 IMS 算法、基于时空联合聚类框架改进的 IMS 算法、3 种典型的轻量化无监督异常检测算法 K-means、iForest 和 KNN 以及一种基于深度学习的智能异常检测算法 AE 对航天器电源系统仿真数据和真实运行数据进行异常检测。实验结果如表 1 和 2 所示。

由实验结果可知,基于本文所提时空联合聚类框架改进的 IMS 算法在保证每帧训练用时和检测用时满足航天器异常检测需求的前提下,在两数据集上较其他方法在准确率 Acc 、 $F1$ 分数和平衡准确率 $Bacc$ 上均有一定提升,同时在精确率 P 和召回率 R 上表现优异。这表明基于时空联合聚类框架改进的 IMS 算法通过对参数时空耦合性的感知,能够挖掘其中蕴含的异常特征,准确检测出航天器复杂时空耦合异常,同时有效减少虚警和漏检情况的发生。与 4 种典型的轻量化无监督异常检测算法传统 IMS、K-means、iForest 和 KNN 相比,改进 IMS 在平衡

表 1 不同异常检测算法的使用效率对比
Table 1 Comparison of the operational efficiency of different anomaly detection algorithms (ms)

数据类型	算法	每帧训练用时	每帧检测用时
仿真数据	IMS	0.091	0.189
	K-means	0.012	0.252
	iForest	0.001	0.001
	KNN	0.548	0.940
	AE	0.623	0.470
	改进 IMS	0.089	0.261
运行数据	IMS	0.805	2.059
	K-means	0.044	0.262
	iForest	0.017	0.005
	KNN	0.084	4.430
	AE	9.205	0.347
	改进 IMS	0.257	0.832

表 2 不同异常检测算法的检测精度对比
Table 2 Comparison of the detection accuracy of different anomaly detection algorithms

数据类型	算法	P	R	Acc	$F1$	$Bacc$
仿真数据	IMS	0.885	1.000	0.904	0.939	0.821
	K-means	0.993	0.890	0.915	0.939	0.937
	iForest	0.957	0.717	0.769	0.820	0.815
	KNN	0.945	1.000	0.957	0.972	0.920
	AE	0.973	0.942	0.939	0.958	0.936
	改进 IMS	0.991	1.000	0.994	0.996	0.988
运行数据	IMS	0.964	1.000	0.971	0.982	0.937
	K-means	1.000	0.915	0.934	0.956	0.957
	iForest	0.999	0.861	0.892	0.925	0.930
	KNN	0.975	1.000	0.980	0.987	0.955
	AE	1.000	0.938	0.952	0.968	0.969
	改进 IMS	1.000	0.985	0.988	0.992	0.992

准确率 $Bacc$ 等多个检测精度指标上表现出明显的优势,这表明应用本文所提时空联合聚类框架进行改进能够有效解决传统基于距离方法在应对航天器复杂时空耦合异常时检测精度显著下降的问题。与基于深度学习的异常检测算法 AE 相比,改进 IMS 在平衡准确率 $Bacc$ 等多个检测精度指标略优的基础上,在使用效率指标上具有明显的优势,这表明在应用本文所提时空联合聚类框架进行方法改进时能够保留传统基于距离方法的轻量化优势,满足航天器在轨异常检测的算法轻量化需求。

2) 消融实验

为了进一步验证时空联合聚类框架对 IMS 算法的改进有效性,实验采用单帧输入改进 IMS、单参数输入改进 IMS、改进 IMS 这 3 种算法对航天器电源系统仿真数据和真实运行数据进行了异常检测。单帧输入改进 IMS 是在基于时空联合聚类框架改进的 IMS 算法基础上,将定义 1 的算法输入修改为单帧遥测数据 $I \in \mathbf{R}^M$,从源头上使得改进 IMS 算法无法捕捉参数时间耦合性特征。单参数输入改进 IMS 是在基于时空联合聚类框架改进的 IMS 算法基础上,将定义 1 的算法输入修改为单参数的滑动时间窗口向量化结果数据 $I \in \mathbf{R}^N$,从源头上使得改进 IMS 算法无法捕捉参数空间耦合性特征。实验结果如表 3 和 4 所示。

表 3 改进 IMS 算法不同输入的使用效率对比
Table 3 Comparison of the operational efficiency of different inputs in the improved IMS algorithm (ms)

数据类型	算法	每帧训练 用时	每帧检测 用时
仿真数据	单帧输入改进 IMS	0.035	0.074
	单参数输入改进 IMS	0.154	0.399
	改进 IMS	0.089	0.261
遥测数据	单帧输入改进 IMS	0.144	0.322
	单参数输入改进 IMS	0.866	2.411
	改进 IMS	0.257	0.832

表 4 改进 IMS 算法不同输入的检测精度对比

Table 4 Comparison of the detection accuracy of different inputs in the improved IMS algorithm

数据类型	算法	P	R	Acc	$F1$	$Bacc$
仿真数据	单帧输入改进 IMS	0.821	1.000	0.841	0.902	0.702
	单参数输入改进 IMS	0.828	1.000	0.847	0.906	0.714
	改进 IMS	0.991	1.000	0.994	0.996	0.988
遥测数据	单帧输入改进 IMS	0.934	1.000	0.946	0.966	0.880
	单参数输入改进 IMS	0.964	1.000	0.971	0.982	0.937
	改进 IMS	1.000	0.985	0.988	0.992	0.992

由实验结果可知,单帧输入改进 IMS 和单参数输入改进 IMS 均只能捕捉参数时空耦合性中单一方面所蕴含异常的特征,在面对参数时空耦合性均蕴含部分异常特征的复杂时空耦合异常时,在精确率 P 、准确率 Acc 、 $F1$ 分数和平衡准确率 $Bacc$ 指标上均较改进 IMS 算法存在劣化。这说明时空联合聚类框架使得改进 IMS 算法能够挖掘复杂时空耦合异常在参数时间耦合性和参数空间耦合性中均蕴含的异常特征,解决传统 IMS 算法在应对航天器复杂时空耦合异常时检测性能显著下降的问题。

5 结 论

本文针对传统基于距离的轻量无监督异常检测方法因无法捕捉参数时空耦合性蕴含的丰富异常特征导致检测性能显著下降的问题,提出了一种时空联合聚类框架。该框架在保留传统基于距离方法轻量化优势的基础上,通过定义一种新型时空距离度量,动态感知并量化参数的时空耦合性特征。在此基础上,本文以 IMS 算法为例,基于所提出的时空联合聚类框架对其进行了针对性改进,从而在不显著增加计算负担的前提下,实现了航天器异常检测在平衡准确率等关键指标上的显著提升,可为以 IMS 算法为代表的基于距离的方法应用于航天器复杂时空耦合异常的检测提供理论支撑与技术路径。

本文的研究仍存在进一步的研究空间。不同参数时间周期尺度不同,在选择时间窗口长度时可针对不同参数的时间周期尺度选取不同的窗口长度;此外,可增加耦合性知识挖掘环节,针对不同类别的耦合性采用针对性的异常判定条件进行异常检测。

参考文献

[1] 罗瑞欣,刘显敏,高宇鹏,等. 基于时序图模式匹配的航天器故障诊断算法[J]. 宇航学报, 2025, 46(2):262-271.
LUO R X, LIU X M, GAO Y P, et al. A spacecraft fault diagnosis algorithm based on temporal graph pattern matching[J]. Journal of Astronautics, 2025, 46(2): 262-271.

[2] 王坤朋,杨文昊,李文博,等. 航天器自主智能运维技术进展[J]. 宇航学报, 2025, 46(2):215-231.
WANG K P, YANG W H, LI W B, et al. Progress in autonomous intelligent maintenance technologies for spacecraft[J]. Journal of Astronautics, 2025, 46(2): 215-231.

[3] 罗懿行,王涵,王路桥,等. 事件触发的航天器在轨自适应故障诊断与恢复[J]. 中国空间科学技术(中英文), 2025, 45(6):11-23.
LUO Y X, WANG H, WANG L Q, et al. Event-triggered adaptive fault diagnosis and recovery for spacecraft in orbit [J]. Chinese Space Science and Technology, 2025, 45(6): 11-23.

[4] YU B, YU Y, YANG ZH M, et al. A novel end-to-end anomaly detection framework for spacecraft using MINE and LSTM-VAE with attention mechanism[J]. Measurement Science and Technology, 2024, 36(1): 015128.

- [5] ZHENG Y Y, MA H, QI Y, et al. Research on anomaly detection algorithm for spacecraft payload action execution status[C]. AOPC 2024: Laser Technology and Applications, 2024, 13492: 434-454.
- [6] 刘切, 李嘉玺, 王泽煜, 等. 基于遥测数据特征预测的轻量化航天器异常检测[J]. 宇航学报, 2025, 46(2): 232-243.
- LIU Q, LI J X, WANG Z Y, et al. Lightweight spacecraft anomaly detection based on telemetry data feature prediction[J]. Journal of Astronautics, 2025, 46(2): 232-243.
- [7] LUAN CH H, XUE X, WANG P CH, et al. Anomaly detection for slowly varying analog telemetry data of spacecraft based on autoencoder[C]. 2024 3rd International Symposium on Sensor Technology and Control, 2024: 307-311.
- [8] HORNE R, MAUW S, MIZERA A, et al. Anomaly detection using deep learning respecting the resources on board a CubeSat[J]. Journal of Aerospace Information Systems, 2023, 20(12): 859-872.
- [9] XIONG B W, XU J W, KONG L R, et al. Gas data anomaly detection based on time-series ARIMA model[C]. International Conference on Electronic Materials and Information Engineering, 2023, 12919: 196-203.
- [10] 王丽娟, 李可爱, 郝志峰, 等. 基于低秩表示的鲁棒回归模型[J]. 计算机工程, 2020, 46(1): 74-79, 86.
- WANG L J, LI K AI, HAO ZH F, et al. Robust regression model based on low rank representation[J]. Computer Engineering, 2020, 46(1): 74-79, 86.
- [11] YING SH, WANG B M, WANG L, et al. An improved KNN-based efficient log anomaly detection method with automatically labeled samples[J]. ACM Transactions on Knowledge Discovery from Data, 2021, 15(3): 1-22.
- [12] 李瑞雪, 张泽旭. 数据驱动的航天器异常检测工具对未来中国空间站管理的启示[J]. 载人航天, 2021, 27(2): 244-251.
- LI R X, ZHANG Z X. Enlightenment of data-driven spacecraft anomaly detection tools on future space station management in China[J]. Manned Spaceflight, 2021, 27(2): 244-251.
- [13] 胡健, 刘学. 基于数据驱动的遥测缓变参数快速全局 K-Means 聚类异常检测包络模型[J]. 舰船电子工程, 2025, 45(2): 129-132, 181.
- HU J, LIU X. Telemetry slowly varying parameters fast global K-Means clustering anomaly detection envelope model based on data driven[J]. Ship Electronic Engineering, 2025, 45(2): 129-132, 181.
- [14] CUI L F, ZHANG Q ZH, SHI Y, et al. A method for satellite time series anomaly detection based on fast-DTW and improved-KNN[J]. Chinese Journal of Aeronautics, 2023, 36(2): 149-159.
- [15] BOLLAM M, ROY P H, JAGTAP A, et al. Anomaly detection in spacecraft telemetry using similarity metrics and isolation forest[C]. 2024 IEEE Space, Aerospace and Defence Conference, 2024: 911-915.
- [16] 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): 247-257.
- 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): 247-257.
- [17] 周金滢, 于劲松, 宋悦, 等. 基于耦合自适应距离的高维异常检测算法[J]. 仪器仪表学报, 2022, 43(8): 182-192.
- ZHOU J H, YU J S, SONG Y, et al. High-dimensional anomaly detection algorithm based on coupling-adaptive distance[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 182-192.
- [18] 孙鹏. 数据驱动的航天器在轨状态关联特征提取与异常检测方法研究[D]. 长沙: 国防科技大学, 2020.
- SUN P. Data driven method for online spacecraft correlated feature extraction and fault detection[D]. Changsha: National University of Defense Technology, 2020.
- [19] 宋华婷, 刘玉荣. 基于符号化表示相似度度量的卫星多元工程参数异常检测[J]. 空间科学学报, 2023, 43(1): 164-173.
- SONG H T, LIU Y R. Multivariate engineering parameter anomaly detection of the satellite based on similarity metric of the symbolic representation[J]. Chinese Journal of Space Science, 2023, 43(1): 164-173.
- [20] 丛安东. 基于正常数据的飞轮系统特征提取及异常检测[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- CONG AN D. Feature extraction and anomaly detection of flywheel system based on normal data[D]. Harbin: Harbin Institute of Technology, 2021.
- [21] 杨甲森, 孟新, 陈托, 等. 基于遥测数据相关性的航天器异常检测[J]. 仪器仪表学报, 2018, 39(8): 24-33.
- YANG J S, MENG X, CHEN T, et al. Anomaly

- detection of spacecraft based on the telemetry data correlation[J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 24-33.
- [22] 李智, 张丽晔, 褚厚斌, 等. 面向飞行器遥测数据的关联规则挖掘方法研究[J]. 计算机测量与控制, 2021, 29(5): 189-192, 197.
- LI ZH, ZHANG L Y, CHU H B, et al. Study on association rules mining method for spacecraft telemetry data[J]. Computer Measurement & Control, 2021, 29(5): 189-192, 197.
- [23] 谢丽霞, 王嘉敏, 杨宏宇, 等. 时间序列异常检测方法研究综述[J]. 中国民航大学学报, 2024, 42(3): 1-12, 18.
- XIE L X, WANG J M, YANG H Y, et al. Review of anomaly detection methods for time series[J]. Journal of Civil Aviation University of China, 2024, 42(3): 1-12, 18.
- [24] ALE T, JANEJA V P, SCHLEGEL N J. Harnessing feature clustering for enhanced anomaly detection with variational autoencoder and dynamic threshold[C]. 2024 IEEE International Geoscience and Remote Sensing Symposium, 2024: 8692-8696.
- [25] LI J B, IZAKIAN H, PEDRYCZ W, et al. Clustering-based anomaly detection in multivariate time series data[J]. Applied Soft Computing, 2021, 100: 106919.
- [26] 李晓博, 江志农, 张沛, 等. 基于 IMS 聚类算法的柴油发动机故障诊断方法研究[J]. 振动与冲击, 2018, 37(7): 193-198, 246.
- LI X B, JIANG ZH N, ZHANG P, et al. Fault diagnosis approach for diesel engines based on IMS clustering algorithm[J]. Journal of Vibration and Shock, 2018, 37(7): 193-198, 246.
- [27] 赵光权, 王盟, 刘大同, 等. 航天器电源建模仿真综述与展望[J]. 仪器仪表学报, 2023, 44(4): 1-18.
- ZHAO G Q, WANG M, LIU D T, et al. Review and perspective survey on spacecraft power supply modeling and simulation[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 1-18.
- [28] YU J S, SONG Y, TANG D Y, et al. Telemetry data-based spacecraft anomaly detection with spatial-temporal generative adversarial networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.

作者简介



郑茗畅, 2023 年于北京航空航天大学获得学士学位, 现为北京航空航天大学硕士研究生, 主要研究方向为故障预测与健康管理技术。

E-mail: zy2303217@buaa.edu.cn

Zheng Mingchang received his B. Sc. degree from Beihang University in 2023. He is currently a M. Sc. candidate at Beihang University. His main research interest is prognostics and health management (PHM) technologies.



于劲松, 1989 年于南京航空航天大学获得学士学位, 1996 年与 2004 年于北京航空航天大学分别获得硕士和博士学位。现为北京航空航天大学自动化科学与电气工程学院教授, 主要研究方向为自动化测试和故障预测与健康管理技术。

E-mail: yujs@buaa.edu.cn

Yu Jinsong received his B. Sc. degree from Nanjing University of Aeronautics and Astronautics in 1989, and his M. Sc. and Ph. D. degrees both from Beihang University in 1996 and 2004, respectively. He is currently a professor in the School of Automation Science and Electrical Engineering at Beihang University. His main research interests include automated testing and prognostics and health management (PHM) technologies.



赵春州, 2023 年于武汉理工大学获得学士学位, 现为北京航空航天大学博士研究生, 主要研究方向为故障预测与健康管理技术。

E-mail: ChunZhou_Zhao@buaa.edu.cn

Zhao Chunzhou received his B. Sc. degree from Wuhan University of Technology in 2023. He is currently a Ph. D. candidate at Beihang University. His main research interest is prognostics and health management (PHM) technologies.



彭宇 (通信作者), 2007 年、2011 年与 2016 年于哈尔滨工程大学分别获得学士、硕士和博士学位。现为北京航天自动控制研究所主任设计师, 主要研究方向为智能故障诊断与健康管理。

E-mail: lyricday@sina.com

Peng Yu (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Harbin Engineering University in 2007, 2011 and 2016, respectively. He is currently the chief designer of Beijing Aerospace Automatic Control Institute. His main research interests include intelligent fault diagnosis and health management.