

# 样本不平衡条件下航天器姿态控制的故障诊断\*

詹明耀, 孟云鹤

中山大学人工智能学院, 广东 珠海 519082

**摘要:** 针对航天器姿态控制系统在故障样本稀缺、样本不平衡条件下的诊断性能下降问题, 提出一种融合时间序列图像编码与深度学习的故障诊断方法。首先, 采用带梯度惩罚的 Wasserstein 生成对抗网络(WGAN-GP)对故障时序样本进行生成增广, 以平衡训练集分布; 其次, 利用 Gramian 角和场、马尔可夫转移场及递归图编码方法将时序信号转换为二维图像; 最后, 构建二维卷积神经网络实现故障特征的提取与分类。实验结果表明, 所提方法在所有样本不平衡比例下均能显著提升诊断准确率, 验证了其对于样本不平衡场景的有效性与鲁棒性。

**关键词:** 航天器姿态控制系统; 故障诊断; 时间序列图像编码; 生成对抗网络; 卷积神经网络

**中图分类号:** V19 **文献标志码:** A **文章编号:** 2097-0137(XXXX)XX-0001-11

## Fault diagnosis of spacecraft attitude control under sample imbalance conditions

ZHAN Mingyao, MENG Yunhe

School of Artificial Intelligence, Sun Yat-sen University, Zhuhai 519082, China

**Abstract:** To address the performance degradation of fault diagnosis in spacecraft attitude control systems under conditions of scarce fault samples and imbalanced data distribution, this paper proposes a fault diagnosis method integrating time-series image encoding and deep learning. First, a Wasserstein Generative Adversarial Network with gradient penalty (WGAN-GP) is employed to augment fault time-series samples and balance the training set distribution. Subsequently, three encoding methods—Gramian Angular Summation Field, Markov Transition Field, and Recurrence Plot—are utilized to convert time-series signals into two-dimensional images. Then, a two-dimensional convolutional neural network is constructed to extract and classify fault features. Experimental results demonstrate that the proposed method significantly improves diagnostic accuracy under varying sample imbalance ratios, validating its effectiveness and robustness in imbalanced sample scenarios.

**Key words:** spacecraft attitude control system; fault diagnosis; time-series image encoding; generative adversarial network; convolutional neural network

航天器姿态控制系统(SACS, spacecraft attitude control system)是航天器的核心子系统。由于在轨航天器具有多样性与复杂性, 且所处环境极端严苛, 其关键部件易发生故障, 不仅影响控制系

统性能, 还可能引发严重事故与经济损失(Venkateswaran et al., 2002; Hedayati et al., 2024a)。因此, 开展高效、准确的故障诊断对提升航天器姿态控制系统健康管理水平具有重要意义。

\* 收稿日期: 2026-01-04

录用日期: 2026-02-28

网络首发日期: XXXX-XX-XX

基金项目: 智控实验室开放基金(ICL-2023-0403)

作者简介: 詹明耀(2001年生), 男; 研究方向: 故障诊断; E-mail: zhanmy7@mail2.sysu.edu.cn

通信作者: 孟云鹤(1978年生), 男; 研究方向: 故障诊断; E-mail: mengyh7@mail.sysu.edu.cn

全文阅读



ZR20260004

现有的故障诊断方法主要可分为基于模型、基于知识、数据驱动及混合方法四大类(沈毅等, 2020)。基于模型的方法依靠系统物理机理建模, 通过残差分析、参数估计等手段进行诊断(Henry, 2008; Gao et al., 2020); 基于知识的方法则依赖专家经验构建知识库进行推理(邱瑞等, 2024)。然而, 随着系统复杂度提高, 精确建模与知识库构建难度日益增大(Pourtakdoust et al., 2023)。近年来, 数据驱动方法通过机器学习直接从数据中学习故障特征, 取得了广泛应用(Suo et al., 2019), 例如: 针对SACS的轻量级CNN设计(Zhao et al., 2024)、多通道CNN传感器故障检测(Gallon et al., 2025)以及将姿态误差转换为图像的CNN诊断方法(Xiao et al., 2020; 梁寒玉等, 2024)。但这类方法依赖大量高质量标注样本, 而航天器在轨故障样本稀少, 存在严重的样本不平衡问题(He et al., 2025)。混合方法虽能融合多种技术优势(Guo et al., 2020; Li et al., 2022; Hedayati et al., 2025), 但结构复杂, 设计与维护难度较高。

在SACS中, 时间序列信号是反映系统动态行为的重要载体。将时间序列编码为图像, 可充分利用CNN在图像特征提取方面的优势。例如, 张达等(2023)提出基于时序二维化(T2D)的故障检测方法, 引入格拉姆角场将时序数据编码为图像, 并利用Vision Transformer提升检测精度; Meng et al. (2026)通过递归图将轴承信号转换为二维图像; Zhang et al. (2025)借助马尔可夫变迁场增强变压器故障特征表达。这类方法在保留时序特征的同时, 能够挖掘数据中的深层模式, 提升诊断准确性。

针对故障样本不足的问题, 生成式算法被用于样本增广以平衡数据集。陆钦华等(2025)针对航空发动机数据稀缺性问题, 研究了基于生成对抗网络(GAN)的预训练数据增强方法; Hedayati et al. (2024b)基于WGAN生成航天器时序数据, 并通过LSTM分类器验证了其有效性; 孙权等(2024)针对逆变器故障样本不均衡问题, 提出了融合条件生成对抗网络(CGAN)与CNN的故障诊断方法。然而, 传统GAN与WGAN存在训练不稳定、梯度消失等问题, 可能导致生成样本失真。

本文提出一种面向SACS的故障诊断方法, 重点解决样本不平衡问题。首先构建基于WGAN-GP的卷积数据生成模型, 用于不平衡航天器时序数据

的增广; 并应用三种图像编码方法将时序数据转换为二维图像, 以提取更丰富、更具判别力的特征, 从而提高故障诊断的准确性; 最后使用2D-CNN进行图像识别与故障分类。

## 1 航天器姿态控制系统建模与故障分析

### 1.1 航天器姿态控制系统建模

航天器姿态控制系统构成一个闭环控制回路, 如图1所示。姿态敏感器测量航天器相对于空间基准的方位信息, 确定航天器姿态; 控制器处理测量数据, 依据控制律生成控制指令; 执行器根据指令产生控制力矩, 驱动航天器调整姿态, 实现精确控制(Chen et al., 2023)。

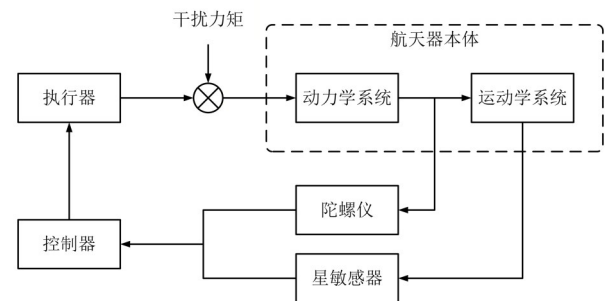


图1 航天器姿态控制系统

Fig. 1 Spacecraft attitude control system

航天器姿态动力学和运动学方程(Chapman et al., 2003; Yang, 2012)可表示为

$$J\dot{\omega} = -\omega^{\times}J\omega + T_c + T_d,$$

$$\dot{q} = \frac{1}{2}\Omega(\omega)q,$$

式中  $\omega = [\omega_x, \omega_y, \omega_z]^T$  为航天器姿态角速度,  $q = [q_0, q_v^T]^T$  为姿态四元数,  $J$  为转动惯量矩阵,  $T_c$  和  $T_d$  分别表示控制力矩和干扰力矩,  $\omega^{\times}$  为斜对称矩阵。其中

$$\omega^{\times} = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix},$$

$$\Omega(\omega) = \begin{bmatrix} 0 & -\omega_x & -\omega_y & -\omega_z \\ \omega_x & 0 & \omega_z & -\omega_y \\ \omega_y & -\omega_z & 0 & \omega_x \\ \omega_z & \omega_y & -\omega_x & 0 \end{bmatrix}.$$

航天器通常配置陀螺仪与星敏感器。陀螺仪

用于测量航天器角速度,其测量模型(Grewal et al., 2007)为

$$\boldsymbol{\omega}_m(t) = \boldsymbol{\omega}(t) + \mathbf{b}(t) + \mathbf{n}_A(t),$$

$$\dot{\mathbf{b}}(t) = \mathbf{n}_R(t),$$

式中  $\boldsymbol{\omega}(t)$  为姿态角速度真实值,  $\boldsymbol{\omega}_m(t)$  为角速度测量值,  $\mathbf{b}(t)$  为陀螺仪等效常值漂移,  $\mathbf{n}_A(t)$ 、 $\mathbf{n}_R(t)$  分别为零均值且方差为 1 的白噪声, 且  $\mathbf{n}_A(t)$  与  $\mathbf{n}_R(t)$  不相关。

星敏传感器用以测量航天器的惯性姿态。星敏传感器的测量模型(Markley et al., 2014)为

$$\bar{q}_0 = \pm \frac{1}{2} (\text{tr} \mathbf{A} + 1)^{\frac{1}{2}},$$

$$\bar{\mathbf{q}}_v = \frac{1}{4q_0} \begin{bmatrix} A_{yz} - A_{zy} \\ A_{zx} - A_{xz} \\ A_{xy} - A_{yx} \end{bmatrix},$$

式中  $\bar{q}_0$  和  $\bar{\mathbf{q}}_v$  分别为四元数测量值的标量和矢量部分,  $\mathbf{A} = \mathbf{M}_m \mathbf{M}_{\text{err}} \mathbf{M}_{\text{ST}} \mathbf{M}(\mathbf{q})$  为星敏传感器测量输出对应的惯性姿态矩阵。其中,  $\mathbf{M}_m$  为测量误差矩阵,  $\mathbf{M}_{\text{err}}$  为星敏安装误差矩阵,  $\mathbf{M}_{\text{ST}}$  为星敏安装矩阵,  $\mathbf{M}(\mathbf{q})$  为由星体真实姿态四元数得到的姿态矩阵。

## 1.2 航天器姿态控制系统故障模型

常见故障类型根据发生部位不同可分为姿态敏感器故障和执行器故障(黄瑾等, 2021)。

**1.2.1 姿态敏感器故障** 姿态敏感器在长期在轨运行过程中易受到器件老化、辐射环境和热应力等因素影响,其常见故障主要包括:

1) 输出封死故障: 表现为传感器输出在故障发生后保持为固定值, 无法反映真实系统状态, 其数学模型可表示为

$$u_{\text{output}}(t) = \begin{cases} u_{\text{real}}(t), & t < t_f, \\ \sigma, & t \geq t_f. \end{cases}$$

2) 常值偏差故障: 传感器输出在原有测量基础上叠加额外的恒定偏置, 其数学模型可表示为

$$u_{\text{output}}(t)(t) = \begin{cases} u_{\text{real}}(t), & t < t_f, \\ u_{\text{real}}(t) + \delta(t), & t \geq t_f. \end{cases}$$

3) 异常噪声增益故障: 传感器测量噪声的统计特性(如方差)发生突变。故障发生后, 测量噪声的幅值显著增大, 其数学模型可表示为

$$u_{\text{output}}(t) = \begin{cases} u_{\text{real}}(t) + u_f(t), & t < t_f, \\ u_{\text{real}}(t) + \eta \cdot u_f(t), & t \geq t_f, \end{cases}$$

式中  $t_f$  为故障发生时刻,  $u_{\text{output}}(t)$  为姿态敏感器的实

际输出,  $u_{\text{real}}(t)$  为姿态敏感器的理论输出,  $\sigma$  为输出封死故障信号,  $\delta$  为偏差故障信号,  $u_f(t)$  为姿态敏感器测量噪声,  $\eta$  为噪声故障增益。

三类故障虽然在物理成因上不同, 但均会导致姿态测量信号在幅值分布、随机波动特性及时间相关性方面发生变化, 并通过控制回路影响系统整体动态行为。

**1.2.2 执行器故障** 执行器故障主要体现在控制力矩输出异常。常见形式包括执行器卡死、空转以及效率下降等。卡死和空转故障会显著削弱系统姿态调节能力, 而效率下降故障则表现为控制力矩幅值减小。

空转故障的数学模型可表示为

$$T_{\text{output}}(t) = \begin{cases} T_{\text{real}}(t), & t < t_f, \\ 0, & t \geq t_f. \end{cases}$$

卡死故障的数学模型可表示为

$$T_{\text{output}}(t) = \begin{cases} T_{\text{real}}(t), & t < t_f, \\ c, & t \geq t_f. \end{cases}$$

效率下降故障的数学模型可表示为

$$T_{\text{output}}(t) = \begin{cases} T_{\text{real}}(t), & t < t_f, \\ KT_{\text{real}}(t), & t \geq t_f, \end{cases}$$

式中  $T_{\text{output}}(t)$  为执行器实际输出力矩,  $T_{\text{real}}(t)$  为执行器理论输出力矩,  $c$  为空转故障信号,  $K$  为执行器效率下降故障增益系数。执行器故障同样会通过闭环控制系统反映到控制指令、角速度响应及姿态变化等时间序列信号中。

## 1.3 数据驱动的故障诊断建模

在实际应用中, 故障参数(如偏差幅值、噪声统计特性变化程度及执行器效率衰减系数)通常具有显著不确定性, 且在轨可获取的真实故障样本数量极为有限。这使得完全依赖精确物理模型的故障诊断方法在实际应用中面临建模复杂、泛化能力不足等问题。

从系统运行来看, 当姿态控制系统中任一环节发生故障时, 其影响会沿闭环控制回路逐级传播, 最终体现在控制指令信号、陀螺仪角速度测量信号及星敏传感器姿态测量信号等多源时间序列数据中。不同类型和不同程度的故障将导致这些时间序列在动态演化模式、统计分布及时序相关性等方面呈现出显著差异。而且, 航天器姿态控制系统的故障数据通常具有以下两个显著特征:

1)故障样本数量少且类别分布严重不平衡,容易导致数据驱动模型偏向正常工况;

2)故障特征主要蕴含于时间序列的动态结构中,单一时域或频域特征难以充分刻画系统的非线性性和非平稳特性。

因此,本文将航天器姿态控制系统故障诊断问题建模为样本不平衡条件下的多变量时间序列模式识别问题,并进一步探索通过数据增广与特征表示变换提升深度学习模型性能的方法,为后续故障诊断算法设计奠定基础。

## 2 基于 WGAN-GP 与时序图像编码的故障诊断方法

本文构建了一种面向样本不平衡条件的航天器姿态控制系统故障诊断方法。该方法的核心思想是:通过生成式模型缓解故障样本稀缺问题,通过时间序列图像编码增强动态特征表达能力,并结合卷积神经网络实现鲁棒的故障模式识别。

### 2.1 基于一维卷积的 WGAN-GP 样本增广模型

为缓解故障样本稀缺与类别不平衡问题,本文引入带梯度惩罚的 Wasserstein 生成对抗网络(WGAN-GP)对姿态控制系统故障时间序列数据进行生成增广。

生成对抗网络(GAN)是一种基于深度学习的高效生成模型,能够学习真实数据的分布并生成高质量的仿真样本(Goodfellow et al., 2014)。然而,传统 GAN 在训练过程中容易出现模式崩溃和梯度消失等问题,导致训练不稳定(Arjovsky et al., 2017)。为克服传统 GAN 训练不稳定、梯度消失等问题,本文采用 WGAN-GP 进行故障时序样本的生成增广(Gulrajani et al., 2017)。WGAN-GP 通过在判别器损失函数中引入梯度惩罚项,以软约束方式确保判别器满足 Lipschitz 条件,其损失函数定义为

$$L_D = -\mathbb{E}_{x \sim p_{\text{real}}} [D(x)] + \mathbb{E}_{z \sim p_z} [D(G(z))] + \lambda \mathbb{E}_{\hat{x} \sim p_{\hat{x}}} \left[ \left( \left\| \nabla_{\hat{x}} D(\hat{x}) \right\|_2 - 1 \right)^2 \right],$$

$$L_G = -\mathbb{E}_{z \sim p_z} [D(G(z))],$$

式中  $\hat{x}$  为真实样本  $x$  和生成样本  $\tilde{x}$  间接随机比例线性插值得到的样本,  $\lambda$  是惩罚系数,通常设置为 10。

本文采用一维卷积结构构建 WGAN-GP 模型,其结构如图 2 所示。生成器采用全连接层(FC)和

卷积核大小为 4、步长为 2 的一维转置卷积层(ConvTranspose1D)堆叠而成,判别器采用卷积核大小为 4、步长为 2 的一维卷积层(Conv1D)和两个全连接层堆叠而成。

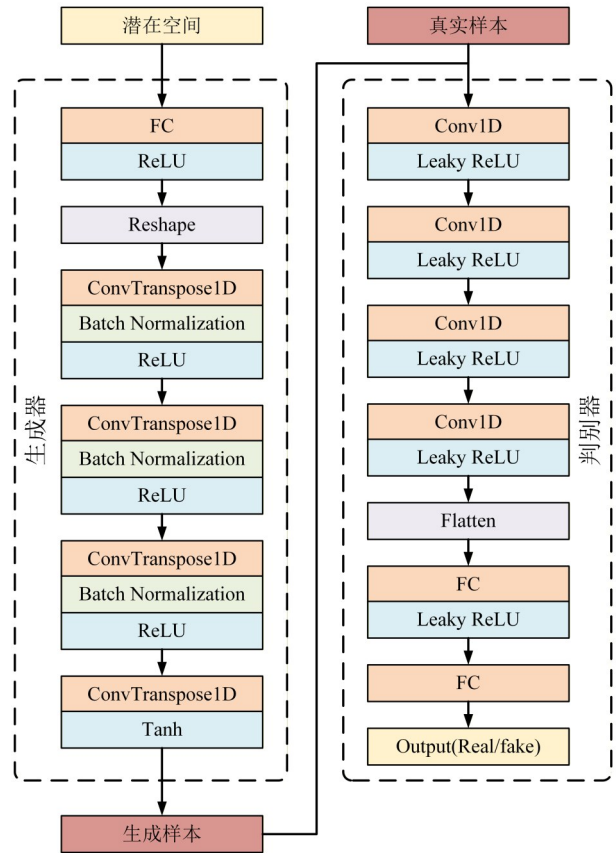


图2 WGAN-GP模型结构

Fig. 2 Structure of WGAN-GP model

训练过程中,潜在噪声维度为 100,批处理大小为 32,总训练轮数为 5 000。优化器采用 Adam,初始学习率为 0.000 1,判别器每更新 5 次后生成器更新 1 次。针对每种故障模式分别训练独立模型,以生成相应故障的高质量样本。

### 2.2 时间序列图像编码方法

考虑到姿态控制系统故障信息主要体现在时间序列的动态演化结构和非线性特征中,本文采用三种典型的时间序列图像编码方法,将一维信号转换为二维图像,以充分挖掘其时序依赖关系。

**2.2.1 格拉姆角和场图像编码** 格拉姆角和场(GASF, Gramian Angular Summation Field)通过极坐标变换将时间序列编码为二维对称矩阵(Wang et al., 2015; Yang et al., 2019)。首先将序列  $X = \{x_1, x_2, \dots, x_n\}$  归一化至  $[-1, 1]$  的区间,并映射为极

坐标角度  $\phi_i = \arccos(\tilde{x}_i)$ , 其中半径  $r_i = t_i/N$ 。然后计算任意两角度之和的余弦值, 并构建 Gramian 矩阵:

$$\mathbf{GASF}_{i,j} = \cos(\phi_i + \phi_j) = \tilde{x}_i \tilde{x}_j - \sqrt{1 - \tilde{x}_i^2} \sqrt{1 - \tilde{x}_j^2}.$$

该编码生成  $N \times N$  对称矩阵, 如图 3 所示, 信息无损失且能通过主对角线渐变模式清晰呈现时间依赖性。




图 3 GASF 编码图

Fig. 3 GASF encoding diagram

**2.2.2 马尔可夫转移场图像编码** 马尔可夫转移场 (MTF, Markov Transition Field) 基于马尔可夫转移概率刻画时间序列的动态演化 (Lei et al., 2023)。先将时间序列值域离散化为  $Q$  个分位数区间, 计算  $Q \times Q$  转移概率矩阵  $\mathbf{W}$ , 其元素  $w_{ij}$  表示从分位数  $q_i$  转移到分位数  $q_j$  的概率。为保留时间依赖关系, 进一步扩展为 MTF 矩阵  $\mathbf{M}$ :

$$\mathbf{M} = \begin{bmatrix} m_{ij|x_1 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_1 \in q_i, x_n \in q_j} \\ m_{ij|x_2 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_2 \in q_i, x_n \in q_j} \\ \vdots & \ddots & \vdots \\ m_{ij|x_n \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_n \in q_i, x_n \in q_j} \end{bmatrix},$$

式中  $m_{ij}$  为分位数  $q_i$  转移到分位数  $q_j$  的转移概率。

通过上述编码, 将时间序列转换为能同时保留状态转移规律与时间依赖关系的二维图像, 如图 4 所示。

**2.2.3 递归图图像编码** 递归图 (RP, Recurrence




图 4 MTF 编码图

Fig. 4 MTF encoding diagram

Plot) 基于相空间重构思想, 将一维时序数据映射至二维图像, 用以揭示时序数据的内部结构、非平稳性及周期性特征 (Marwan et al., 2007)。设定阈值  $\varepsilon$ , 递归图矩阵元素定义为:

$$\mathbf{RP}_{i,j} = \begin{cases} 1, & \text{if } \|\vec{x}_i - \vec{x}_j\| \leq \varepsilon, \\ 0, & \text{其他.} \end{cases}$$

采用点百分比阈值法确定  $\varepsilon$ , 取距离矩阵中距离值的第 35 个百分位数作为阈值, 编码结果如图 5 所示, 可直观反映动态系统的均匀性、周期性、漂移等特性。




图 5 RP 编码图

Fig. 5 RP encoding diagram

上述方法均能将时序数据转换为适合卷积神经网络处理的二维图像格式, 为后续特征提取与故障诊断提供有效的数据表示。

### 2.3 二维 CNN 故障分类网络设计

在完成样本扩增与时间序列图像编码后, 本文采用二维卷积神经网络 (2D-CNN) 对编码后的图像进行特征提取与故障分类。2D-CNN 是一种专用于处理图像数据的前馈神经网络, 通过卷积、池化等操作自动提取空间特征, 在图像识别领域表现优异 (Goodfellow et al., 2014)。本文构建的 2D-CNN 由卷积核大小为  $3 \times 3$  的二维卷积层、池化层、全连接层等模块构成, 其结构如图 6 所示。

卷积层通过可学习的滤波器对输入图像进行特征提取, 池化层对特征图进行下采样, 常用最大池化操作, 以提升模型的鲁棒性, 全连接层则负责整合高级特征并输出分类结果。

网络训练采用 Adam 优化器, 初始学习率设为 0.001, 损失函数为交叉熵损失, 批次大小为 64, 训练迭代 50 次。为全面评估诊断性能, 使用准确率、召回率、精确率和 F1 分数作为评价指标, 并与 BP 神经网络、LSTM、1D-CNN 以及基于 GAN 和 WGAN 的对照方法进行比较, 以验证本文方法的有效性。

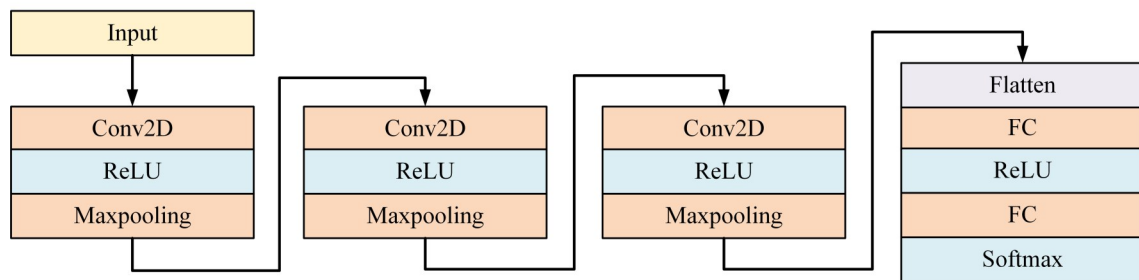


图6 2D-CNN模型

Fig. 6 Designed 2D-CNN mode

## 2.4 整体故障诊断框架

图7给出了本文所提出的姿态控制系统故障诊断的完整流程和框架。此故障诊断系统主要由四个部分组成:1)数据获取,数据采集基于固定目标姿态四元数和随机初始化初始四元数,通过随机故障时间触发,获取航天器姿态的原始故障数据,保证样本

多样性和代表性;2)故障样本增广,将每种故障模式的样本分别输入给WGAN-GP网络进行数据增广;3)时间序列二维图像编码,通过RP、GASF和MTF将原始样本和增广样本转换为二维图像格式;4)CNN网络故障诊断,将转换后的增广训练集输入给CNN分类网络进行训练,对测试集进行故障诊断。

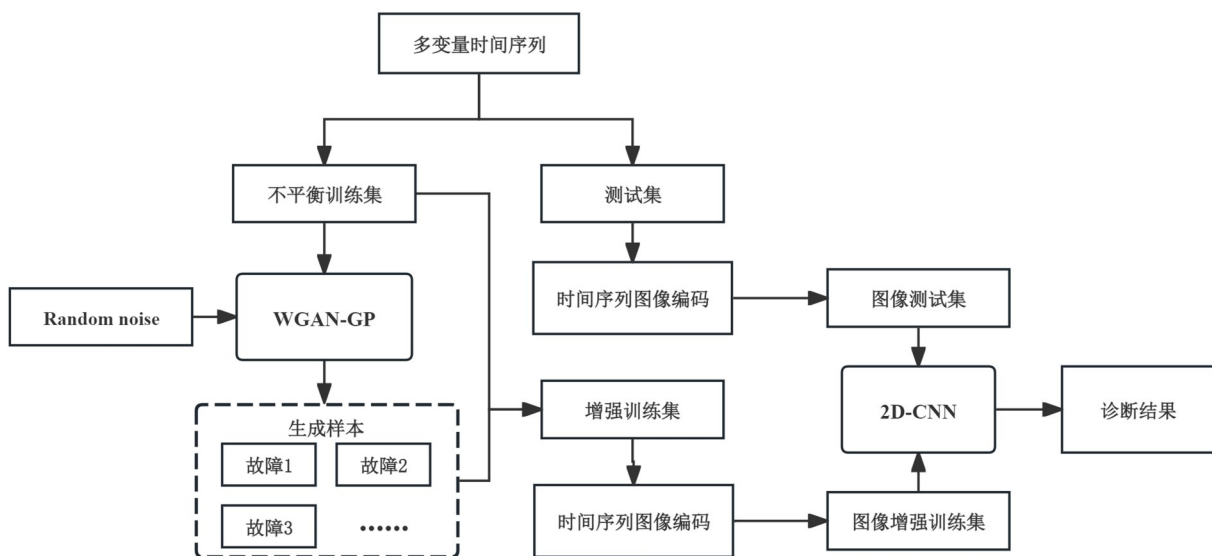


图7 时间序列图像编码和2D-CNN结合的故障诊断框架

Fig. 7 Framework of the fault diagnosis method combining time series image encoding and 2D-CNN

## 3 仿真分析

针对航天器姿态控制系统中执行器空转、执行器卡死、执行器效率下降、星敏传感器输出封死、星敏传感器常值偏差、星敏传感器异常噪声增益、陀螺仪输出封死、陀螺仪常值偏差、陀螺仪异常噪声增益9种典型故障及正常模式(共10类)开展实验。所有数据均通过仿真生成,系统模型基于Simulink构建,采用PD控制器 $T_U = -K_d \omega_e - K_p q_{ve}$ ,其中 $\omega_e$ 为角速度误差, $q_{ve}$ 为姿态四元数误差的矢量部分。并设定惯性矩阵 $J =$

$[0.763, 1.414, 1.047] \text{ kg} \cdot \text{m}^2$  与控制参数 $K_d = [8, 8, 8]^T$ , $K_p = [0.08, 0.06, 0.07]^T$ 。仿真采样数据为控制指令力矩以及星敏传感器与陀螺仪的测量输出,采样周期为0.1 s,窗口长度为64,通过随机故障注入获取原始数据。

为系统评估类别不平衡的影响,训练集按7种不平衡比(10:1至1 000:1)设置,正常样本固定为1 000个,故障样本相应递减;测试集每类包含500个平衡样本。在1 000:1的极端不平衡情况下,将

批归一化替换为层归一化以保证网络训练稳定。

### 3.1 样本不平衡条件下的诊断性能

在不同的类别不平衡比例条件下,对多种数据驱动故障诊断方法进行了性能评估,结果如图 8 所

示。所有模型均运行 10 次后取平均值,以确保结果稳定。随着故障样本减少和不平衡比例的增大,各模型的准确率、精确率、召回率和 F1 分数均呈现下降趋势。

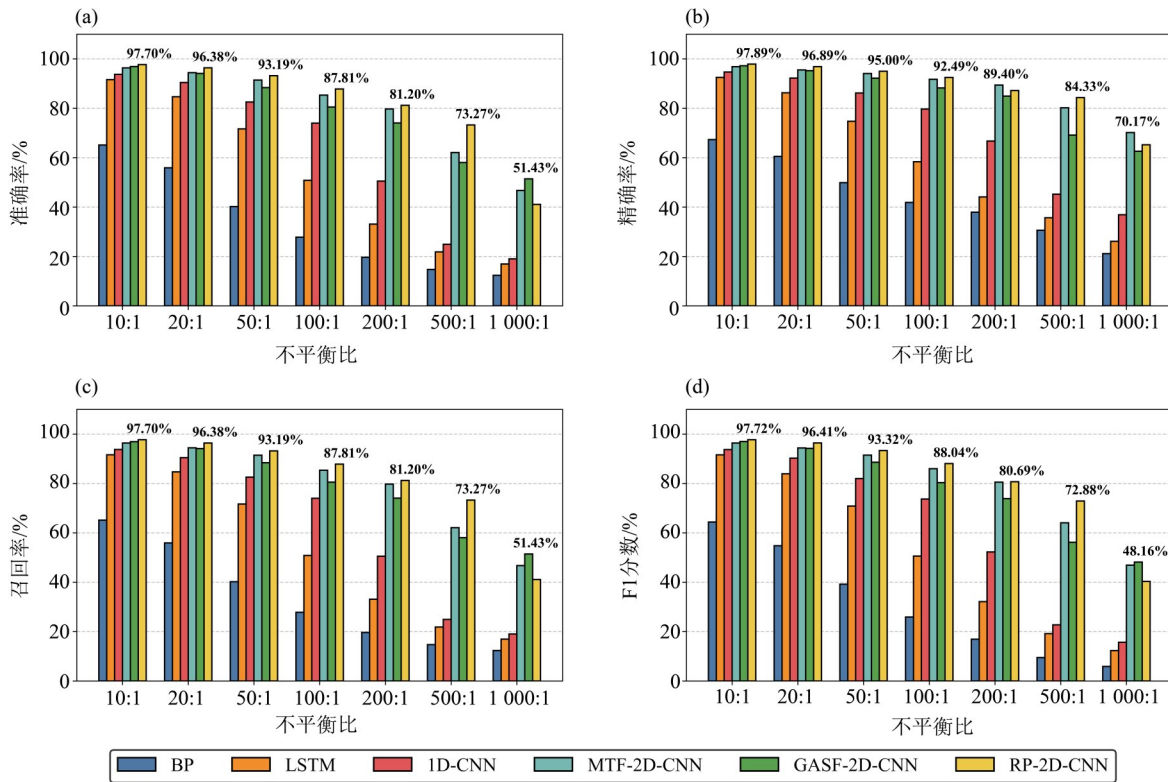


图 8 样本不平衡条件下的故障诊断性能

Fig. 8 Performance of fault diagnosis under sample imbalance

实验表明,使用时序图像编码(GASF、MTF、RP)与 2D-CNN 结合的方法,其各项指标均显著优于 LSTM 和 1D-CNN,验证了图像编码在特征提取上的优势。进一步比较三种编码方法发现,在多数不平衡比例下,RP 编码在各项指标上均优于 GASF 和 MTF;仅在极端不平衡情况下(如 1 000:1),GASF 在部分指标上略优于 RP 方法。

为明确时序图像编码的优势,将 1D-CNN 与 RP-2D-CNN 方法进行对比,结果如图 9 和表 1 所示。RP-2D-CNN 在所有不平衡比例下均表现出性能提升,且随着样本不平衡加剧,提升效果越显著。例如在 500:1 时,准确率提升了 48.33%,F1 分数提升了 50.12%。

### 3.2 WGAN-GP 生成样本质量分析

为评估生成样本的质量,采用多项指标进行分析,并结合 T-SNE(t-Distributed Stochastic Neighbor Embedding)可视化进行特征分布观察。如表 2 所

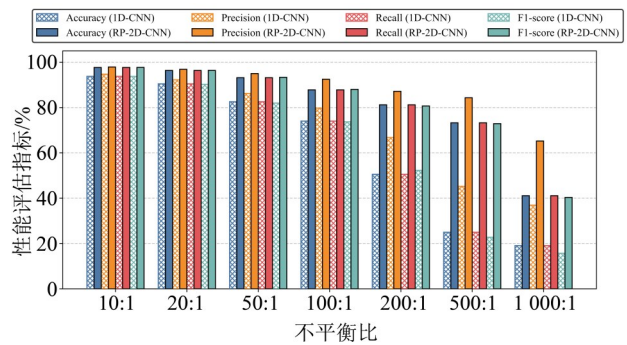


图 9 1D-CNN 和 RP-2D-CNN 方法的性能指标

Fig. 9 Performance indicators of 1D-CNN and RP-2D-CNN

示,在各项相似性度量中,传统 GAN 在各项指标上均表现最优,说明其生成的信号在数值层面与训练数据高度接近;WGAN 在各指标上均表现较弱;而 WGAN-GP 介于两者之间,显著优于 WGAN,说明其在多项相似性指标上保持了较好平衡。

如图 10 所示,通过 T-SNE 可视化可以发现,传统 GAN 生成的样本在特征空间中与真实样本明显

表 1 1D-CNN 与 RP-2D-CNN 模型各评价指标的改进

Table 1 Improvement of each evaluation indicator between 1D-CNN and RP-2D-CNN model

不平衡比	评价指标/%			
	准确率(↑)	精确率(↑)	召回率(↑)	F1分数(↑)
10:1	3.95	3.20	3.95	4.01
20:1	5.59	4.67	5.59	6.16
50:1	10.63	8.81	10.63	11.34
100:1	13.81	12.79	13.81	14.36
200:1	30.67	20.44	30.67	28.42
500:1	48.33	39.10	48.33	50.12
1 000:1	22.04	28.31	22.04	24.65

表 2 生成样本与训练样本的相似度比较

Table 2 Similarity comparison between generated samples and training samples

方法	评价指标			
	欧氏距离(↓)	KL 散度(↓)	PCC(↑)	DTW(↓)
GAN	2.262 8	0.094 8	0.995 2	12.146 6
WGAN	2.677 6	0.126 2	0.394 3	13.987 6
WGAN-GP	2.367 9	0.102 1	0.861 2	13.122 9

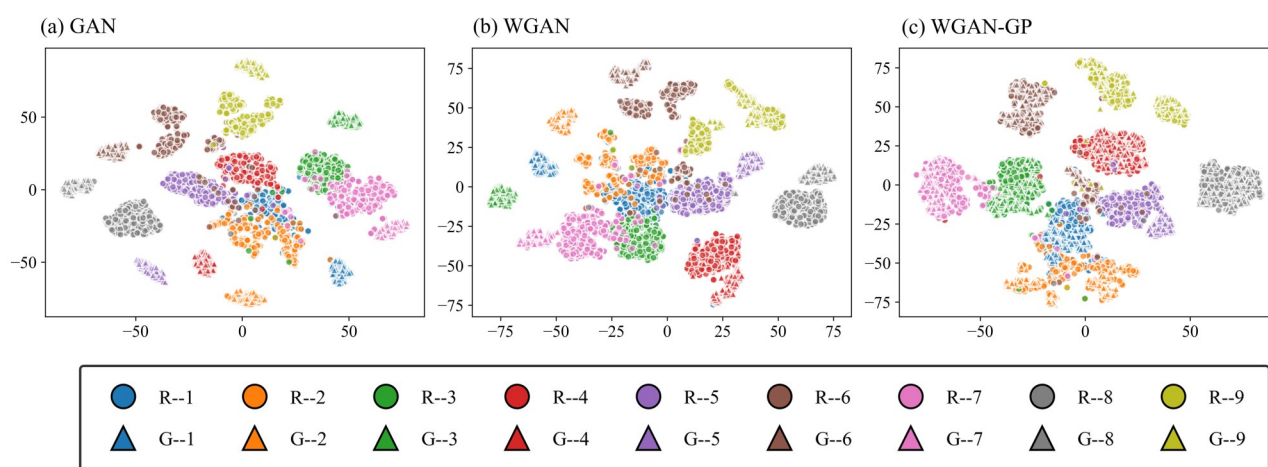


图 10 生成样本的特征空间可视化(T-SNE)

Fig. 10 Feature space visualization of generated samples by T-SNE

分离,提示其可能过拟合于表面数值而未能捕捉深层分布;WGAN-GP则表现出与真实样本更贴近的特征分布,具备更好的特征学习能力与多样性。

综上所述,WGAN-GP在多项相似性指标上表现均衡,且能更好地反映真实数据的特征结构,适用于不平衡故障数据的增广任务。

### 3.3 生成样本对诊断性能的提升

为验证WGAN-GP生成样本对故障诊断性能的提升,本研究将各故障类别的训练样本统一增广至200个,构建平衡训练集。图11及表3结果表明,

经WGAN-GP增广后,大多数诊断模型的性能均获得提升。其中,WGAN-GP与RP-2D-CNN的组合在绝大多数不平衡比例下表现最优,表明RP编码能有效协同WGAN-GP生成的高质量样本。

表3量化了WGAN-GP带来的准确率提升。随着不平衡程度的加剧,提升效果愈显著,例如:LSTM和1D-CNN在较高不平衡比下的提升超过了10%。在1 000:1的极端情况下,WGAN-GP仍使RP-2D-CNN的准确率大幅提升14.53%,显示了其应对样本稀缺的有效性。

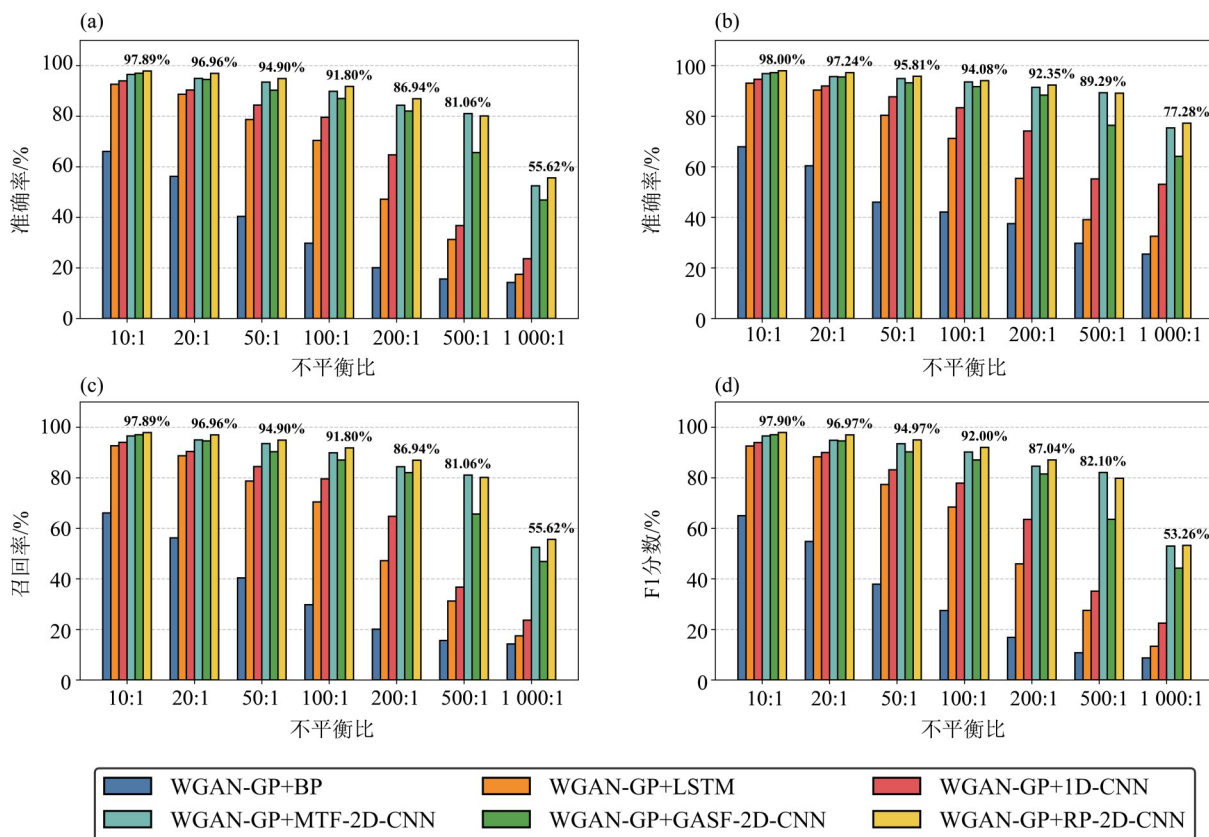


图 11 基于 WGAN-GP 生成模型的故障诊断性能

Fig. 11 Performance of WGAN-GP based on generative model in fault diagnosis

表 3 WGAN-GP 模型对各方法准确率的提升

Table 3 Improvement in accuracy for various methods by WGAN-GP

不平衡比	准确率(↑)/%					
	BP	LSTM	1D-CNN	MTF-2D-CNN	GASF-2D-CNN	RP-2D-CNN
10:1	0.94	1.04	0.24	0.19	0.09	0.19
20:1	0.31	4.01	-0.04	0.54	0.45	0.58
50:1	0.15	7.05	1.86	2.08	1.92	1.71
100:1	1.95	19.60	5.57	4.54	6.51	3.99
200:1	0.44	14.06	14.20	4.64	8.00	5.74
500:1	0.89	9.39	11.81	18.96	7.61	6.86
1000:1	1.89	0.51	4.60	5.75	-4.55	14.53

对比不同生成模型 (GAN、WGAN、WGAN-GP) 与 RP-2D-CNN 结合的故障诊断性能, 结果如图 12 所示。在 10 : 1 的不平衡比下, WGAN 性能略优; 在其他的不平衡比例下, WGAN-GP 性能均显著优于 GAN 和 WGAN, 且随着不平衡程度加剧 (如 500 : 1、1 000 : 1), 其提升幅度尤为明显, 最高达到了 14.53%。这表明 WGAN-GP 在生成样本的质量与多样性之间取得了更好平衡, 能更有效地缓解样本稀缺导致的过拟合问题, 显著提升不平衡条件下的

故障诊断鲁棒性。

## 4 结 论

本文提出了一种融合 WGAN-GP 样本增广与时序图像编码的航天器姿态控制系统故障诊断方法。实验表明: 1) 将时序信号通过 GASF、MTF、RP 编码为图像, 能有效提升 2D-CNN 的特征提取与诊断性能。2) 所提出的时间序列图像编码和 2D-CNN 诊断模型在各不平衡比上均优于其他常用的数据

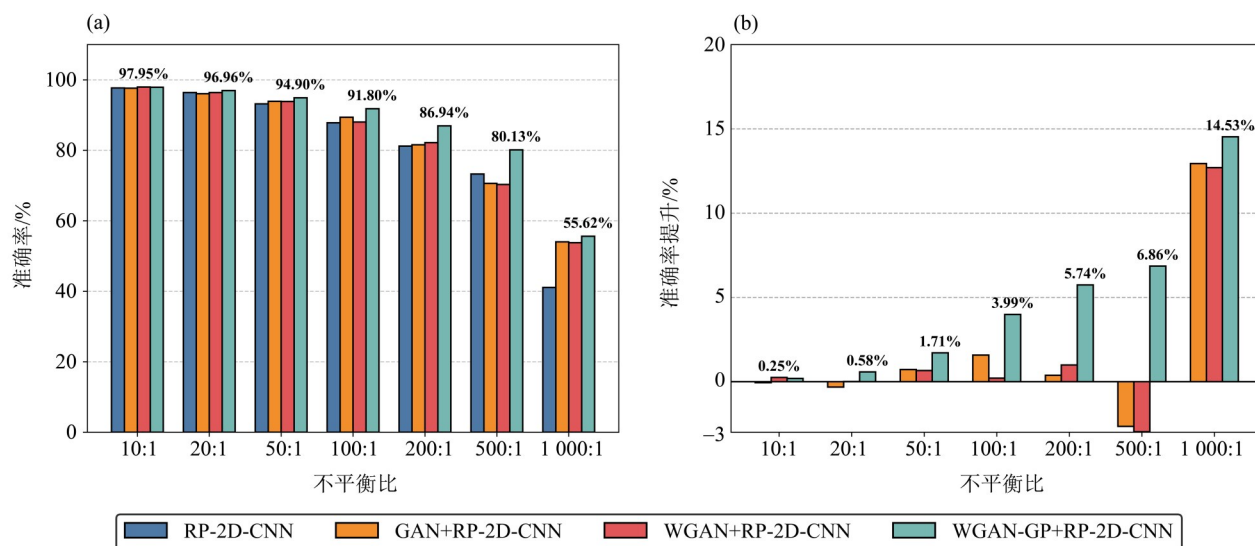


图 12 (a) 不同生成模型 (结合 RP-2D-CNN) 的故障诊断准确率, (b) 三种样本增广方法相较于基准的准确率提升  
Fig. 12 (a) Fault diagnosis accuracy of different generative models combined with RP-2D-CNN, (b) Accuracy improvement of three sample augmentation methods compared to baseline

驱动方法,并且能更准确地检测和诊断 SACS 故障。  
3) WGAN-GP 能生成高质量样本,其增广效果显著优于 GAN 与 WGAN,最高能使故障诊断准确率提升 18.96%。

尽管本文所提方法在仿真实验中表现出良好

性能,但仍存在以下局限:一是仿真数据与真实在轨数据存在差异;二是未考虑多故障并发情况。未来工作将围绕真实数据验证、多故障诊断以及轻量化网络部署展开。

### 参考文献:

- 黄瑾,刘洋,钟麦英,等,2021. 利用随机森林算法的卫星控制系统故障诊断[J]. 宇航学报,42(4):513-521.
- 梁寒玉,刘成瑞,刘文静,等,2024. 基于序列-图像映射的航天器智能故障诊断方法[J]. 飞控与探测,7(1):62-71.
- 陆钦华,陈嘉宇,王旭航,等,2025. 数据不平衡故障诊断:一种预训练数据增强方法[J]. 测控技术,44(1):10-21.
- 邱瑞,姚全营,刘鹏,等,2024. 基于动态不确定因果图的航天器故障诊断方法[J]. 航天器工程,33(5):9-14.
- 沈毅,李利亮,王振华,2020. 航天器故障诊断与容错控制技术综述[J]. 宇航学报,41(6):647-656.
- 孙权,彭飞,李宏胜,等,2024. 样本不均衡下基于 CGAN-CNN 的逆变器故障诊断方法[J]. 电源学报,22(6):318-326.
- 张达,高君宇,丁腾欢,等,2023. 基于时序二维化的航空传感器故障检测[J]. 西北工业大学学报,41(6):1033-1043.
- ARJOVSKY M, CHINTALA S, BOTTOU L, 2017. Wasserstein generative adversarial networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney, NSW, Australia: 214-223.
- CHAPMAN P, ZENTGRAF P, JAFRY Y, 2003. Drag-Free Control Design Including Attitude Transition for the

- STEP Mission[J]. Spacecraft Guidance, Navigation and Control Systems, 516: 551.
- CHEN S, YANG R, ZHONG M, et al, 2023. A random forest and model-based hybrid method of fault diagnosis for satellite attitude control systems[J]. IEEE Trans Instrum Meas, 72: 3518413.
- GAO S, ZHANG W, HE X, 2020. Observer-based multiple faults diagnosis scheme for satellite attitude control system[J]. Asian J Control, 22(1): 307-322.
- GALLON R, SCHIEMENZ F, MENICUCCI A, et al, 2025. Convolutional neural network design and evaluation for real-time multivariate time series fault detection in spacecraft attitude sensors[J]. Adv Space Res, 76(5): 2960-2976.
- GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al, 2014. Generative adversarial nets [EB/OL]. MIT Press. DOI:10.3156/JSOFT.29.5\_177\_2.
- GREWAL M S, WEILL L R, ANDREWS A P, 2007. Global Positioning Systems, Inertial Navigation, and Integration [M]. New York: John Wiley & Sons.
- GULRAJANI I, AHMED F, ARJOVSKY M, et al, 2017.

- Improved training of Wasserstein GANs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, California, USA: 5769–5779.
- GUO X G, TIAN M E, LI Q, et al, 2020. Multiple-fault diagnosis for spacecraft attitude control systems using RBFNN-based observers[J]. *Aerosp Sci Technol*, 106: 106195.
- HE W, LIN L, FU S, et al, 2025. Differential contrast guidance for aeroengine fault diagnosis with limited data[J]. *J Intell Manuf*, 36(2): 1409–1427.
- HEDAYATI M, RAHIMI A, 2025. A hybrid framework for real-time satellite fault diagnosis using Markov jump-adjusted models and 1D sliding window Residual Networks[J]. *Acta Astronaut*, 228: 1066–1087.
- HEDAYATI M S, BARZEGAR A, RAHIMI A, 2024. Fault diagnosis and prognosis of satellites and unmanned aerial vehicles: A review[J]. *Appl Sci–Basel*, 14(20): 9487.
- HEDAYATI M S, BARZEGAR A, RAHIMI A, 2024 . Mitigating data scarcity for satellite reaction wheel fault diagnosis with Wasserstein generative adversarial networks [C]//2024 IEEE International Conference on Prognostics and Health Management. Spokane, WA, USA: 367–376.
- HENRY D, 2008. Fault diagnosis of microscope satellite thrusters using H-infinity/H\_ filters[J]. *J Guid Control Dyn*, 31(3): 699–711.
- LeCUN Y, BENGIO Y, HINTON G, 2015 . Deep learning [J]. *Nature*, 521(7553): 436–444.
- LEI C, MIAO C, WAN H, et al, 2023. Rolling bearing fault diagnosis method based on MTF–MFACNN [J]. *Meas Sci Technol*, 35(3): 035007.
- LI Y, HU Q, SHAO X, 2022 . Neural network-based fault diagnosis for spacecraft with single-gimbal control moment gyros[J]. *Chin J Aeronaut*, 35(7): 261–273.
- MARKLEY F L, CRASSIDIS J L, 2014. Fundamentals of spacecraft attitude determination and control [M]. New York: Springer.
- MARWAN N, ROMANO M C, THIEL M, et al, 2007. Recurrence plots for the analysis of complex systems[J]. *Phys Rep*, 438(5/6): 237–329.
- MENG L, XIE J, CHENG L, et al, 2026. Multi-condition bearing fault diagnosis method based on RP – MBRN[J]. *Struct Health Monit*, 25(1): 456–467.
- POURTAJKDOUST S H, FAKHARI MEHRJARDI M, HAJKARIM M H, et al, 2023. Advanced fault detection and diagnosis in spacecraft attitude control systems: Current state and challenges[J]. *J Aerosp Eng*, 237(12): 2679–2699.
- SUO M, ZHU B, AN R, et al, 2019. Data-driven fault diagnosis of satellite power system using fuzzy Bayes risk and SVM[J]. *Aerosp Sci Technol*, 84: 1092–1105.
- VENKATESWARAN N, SIVA M S, GOEL P S, 2002. Analytical redundancy based fault detection of gyroscopes in spacecraft applications[J]. *Acta Astronaut*, 50(9): 535–545.
- WANG Z, OATES T, 2015. Imaging time-series to improve classification and imputation [EB/OL]. arXiv: 1506.00327. <https://arxiv.org/abs/1506.00327>.
- XIAO B, YIN S, 2020. A deep learning based data-driven thruster fault diagnosis approach for satellite attitude control system [J]. *IEEE Trans Ind Electron*, 68(10): 10162–10170.
- YANG C L, CHEN Z X, YANG C Y, 2019. Sensor classification using convolutional neural network by encoding multivariate time series as two-dimensional colored images[J]. *Sensors*, 20(1): 168.
- YANG Y, 2012. Spacecraft attitude determination and control: Quaternion based method [J]. *Annu Rev Control*, 36: 198–219.
- ZHANG X, YANG K, 2025. Transformer fault diagnosis method based on MTF and GhostNet[J]. *Measurement*, 249: 117056.
- ZHAO H, LIU M, SUN Y, et al, 2024. Automated design of fault diagnosis CNN network for satellite attitude control systems[J]. *IEEE Trans Cybern*, 54(7): 4028–4038.

(责任编辑 王海蓉)