航 空 学 报
Acta Aeronautica et Astronautica Sinica
Jun. 25 2020 Vol. 41 No. S1
ISSN 1000-6893 CN 11-1929/V
http://hkxb.buaa.edu.cn hkxb@buaa.edu.cn

引用格式：程月华，江文建，杨浩，等. 基于深度森林的卫星ACS执行机构与传感器故障识别[J]. 航空学报，2020，41(S1)：723778. CHENG Y H，JIANG W J，YANG H，et al. Fault identification of actuators and sensors of satellite attitude control systems based on deep forest algorithm[J]. Acta Aeronautica et Astronautica Sinica，2020，41(S1)：723778 (in Chinese). doi：10.7527/S1000-6893.2019.23778

基于深度森林的卫星ACS执行机构与传感器故障识别

程月华[1,*]，江文建[1]，杨浩[1]，薛琪[1]，廖鹤[2]

1. 南京航空航天大学 自动化学院，南京 211100
2. 南京航空航天大学 航天学院，南京 210016

摘 要：针对卫星姿态控制系统(ACS)闭环回路的故障难以辨识的问题，引入深度森林算法，实现执行机构与传感器故障识别。首先针对可获取的少量卫星姿态控制系统遥测数据，结合系统动力学特性，研究合适的特征选择和特征提取方法，再结合深度森林算法进行故障信息学习与辨识，建立故障预测模型，实现执行机构故障与传感器故障的识别。半物理仿真结果表明：在存在气浮台干扰力矩、卫星转动惯量未知、飞轮非线性特性、闭环故障传播等多种不利因素情况下，深度森林算法对于执行机构和传感器故障具有高效的识别能力。

关键词：深度森林算法；卫星姿态控制系统；执行机构；传感器；故障识别

中图分类号：V474 **文献标识码**：A **文章编号**：1000-6893(2020)S1-723778-11

卫星姿态控制系统(Attitude Control System，ACS)执行机构或传感器发生故障，会引发卫星ACS姿态失稳、丢失姿态，从而影响卫星平台的安全稳定运行[1-2]。开展卫星ACS执行机构与传感器故障识别研究，可有效地监测卫星ACS的运行状态，在故障发生时及时识别故障类型，采取措施隔离故障，对提高卫星在轨可靠性和安全性具有重要意义[3]。

近年来，国内外学者针对航天器执行机构和传感器的故障诊断问题，开展了诸多的基于模型和基于信号处理的研究工作，并取得了丰硕的研究成果[4-5]。由于卫星ACS组成部件多、空间环境复杂，难以建立精确的数学模型，故基于模型的故障诊断方法应用于卫星ACS具有一定的局限性。近年来，随着计算机与人工智能技术的不断发展以及大量机器学习算法的相继问世，基于数据驱动的智能故障诊断方法被广泛地应用于卫星ACS的故障诊断[6-8]。基于数据驱动的智能故障诊断方法主要通过运用典型的机器学习算法，如人工神经网络(Artificial Neural Network，ANN)[9-10]、支持向量机(Support Vector Machine，SVM)[11-12]和随机森林(Random Forest，RF)[13]等，对卫星执行机构系统的高维采样数据进行表征学习，发现故障数据特征与故障模式之间的联系，从而实现卫星执行机构系统的故障诊断。其中ANN由于其高度的并行处理、联想记忆、自学习以及极强的非线性映射能力而被广泛应用。如文献[9]提出一种基于ANN观测器的陀螺故障诊断方法，利用ACS内的冗余关系设计故障诊断逻辑，同时利用先验模型知识和ANN

收稿日期：2019-12-13；**退修日期**：2019-12-26；**录用日期**：2019-12-31；**网络出版时间**：2020-01-03 13:53
网络出版地址：http://hkxb.buaa.edu.cn/CN/html/2020S120.html
基金项目：国家重点研发计划(2016YFB0500803)；装备预研国防科技重点实验室基金(1422080307)
* **通信作者**. E-mail：chengyuehua@nuaa.edu.cn

的非线性建模特性对陀螺故障进行估计，实现了对卫星 ACS 陀螺的故障诊断。文献[10]利用动态 ANN 模拟反作用飞轮的运行特性，实现了对卫星 ACS 的故障诊断。但是，ANN 模型的准确性，通常依赖大量的数据作为训练样本。而卫星发生故障的概率低，故障样本少，利用 ANN 对卫星 ACS 建立故障模型，其模型准确性势必会受到一定的影响。同时 ANN 也存在训练时间长、参数调整复杂、易陷入局部最优等问题。针对卫星故障样本少的问题，文献[11]利用 SVM 对提取到的少量故障特征样本进行分类，实现了卫星 ACS 执行机构的故障检测与识别。但是，SVM 是一种典型的二分类算法，在解决卫星 ACS 多种故障模式分类问题时存在一定的困难。同时 SVM 也存在对缺失数据敏感，对参数和核函数的选择敏感等问题。

近年来，随着深度学习(Deep Learning)的概念被提出，深度神经网络(Deep Neural Network，DNN)由于其强大的表征学习能力和拟合能力，成为基于数据驱动的智能故障诊断领域的研究热点之一[14]。但 DNN 同样存在对训练样本要求高、对超参数敏感和训练时间长等问题。而卫星的故障样本较少，星载计算机性能不高且实时性要求高，因此 DNN 尚未应用于卫星故障诊断。文献[15-16]在 DNN 基础上提出了一种基于决策树的集成分类算法，称作深度森林(Deep Forest)算法或多粒度级联森林算法(multi-grained cascade forest，gcForest)。该算法不仅具有强大的表征学习能力，同时也对训练样本量要求不高，训练速度快，超参数少且对超参数的选择不敏感等优势。文献[17]将深度波尔兹曼机(Deep Boltzmann Machine，DBM)与深度森林相结合应用于工业故障诊断。本文针对存在环境干扰力矩、卫星转动惯量未知、飞轮非线性特性、闭环故障传播等诸多不利因素的卫星姿态控制系统发生传感器和执行机构故障情形，利用可获取的少量遥测数据信息，研究合适的特征选择和特征提取方法；利用深度森林强大的泛化能力对故障信息进行学习与辨识，建立故障预测模型，实现传感器与执行机构的故障辨识。

1 问题的提出

卫星 ACS 结构如图 1 所示，由控制器、执行机构、卫星本体以及传感器组成。图中：$\boldsymbol{q}_{\mathrm{d}}$ 为卫星期望姿态；$\boldsymbol{\omega}_{\mathrm{i}}$ 和 $\boldsymbol{q}_{\mathrm{i}}$ 分别为卫星当前角速度和姿态角；$\boldsymbol{\omega}_{\mathrm{o}}$ 为陀螺仪实际输出；$\boldsymbol{q}_{\mathrm{o}}$ 为姿态敏感器实际输出值；$\boldsymbol{M}_{\mathrm{s}}$ 为执行机构实际输出力矩；$\boldsymbol{M}_{\mathrm{d}}$ 为卫星所受空间环境干扰；$\boldsymbol{f}_{\mathrm{a}}$ 为执行机构故障模型；$\boldsymbol{f}_{\mathrm{s}}$ 为传感器故障模型。

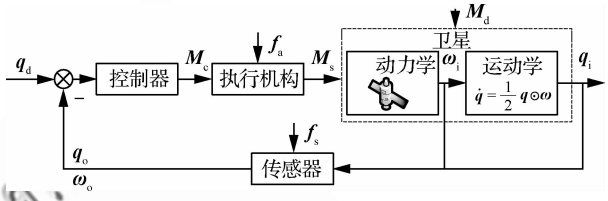


图 1 卫星 ACS 结构框图

Fig. 1 Structure diagram of satellite attitude control systems

定义卫星 ACS 姿态运动学描述为

$$\dot{\boldsymbol{q}}=\frac{1}{2}\boldsymbol{q}\odot\boldsymbol{\omega}=\frac{1}{2}\boldsymbol{\Xi}(\boldsymbol{q})\boldsymbol{\omega} \tag{1}$$

式中：$\boldsymbol{\omega}$ 为角速度；$\boldsymbol{q}=[\boldsymbol{q}_{1:3}^{\mathrm{T}}\ \ q_4]^{\mathrm{T}}=[q_1\ \ q_2\ \ q_3\ \ q_4]^{\mathrm{T}}$ 为航天器姿态四元数，

$$[\boldsymbol{q}\odot]=\begin{bmatrix}q_4\boldsymbol{I}_3+[\boldsymbol{q}_{1:3}\times] & \boldsymbol{q}_{1:3}\\ -\boldsymbol{q}_{1:3}^{\mathrm{T}} & q_4\end{bmatrix}=[\boldsymbol{\Xi}(\boldsymbol{q})\quad\boldsymbol{q}] \tag{2}$$

$$\boldsymbol{\Xi}(\boldsymbol{q})=\begin{bmatrix}q_4\boldsymbol{I}_3+[\boldsymbol{q}_{1:3}\times]\\ -\boldsymbol{q}_{1:3}^{\mathrm{T}}\end{bmatrix}=\begin{bmatrix}q_4 & -q_3 & q_2\\ q_3 & q_4 & -q_1\\ -q_2 & q_1 & q_4\\ -q_1 & -q_2 & -q_3\end{bmatrix} \tag{3}$$

本文 ACS 的执行机构为动量轮，得到的卫星 ACS 的姿态动力学方程为

$$\boldsymbol{J}_{\mathrm{s}}\dot{\boldsymbol{\omega}}+\boldsymbol{\omega}\times(\boldsymbol{J}_{\mathrm{s}}\boldsymbol{\omega}+\boldsymbol{H}_{\mathrm{w}})=\boldsymbol{M}_{\mathrm{c}}+\boldsymbol{M}_{\mathrm{d}} \tag{4}$$

式中：$\boldsymbol{J}_{\mathrm{s}}$ 为卫星转动惯量矩阵；$\boldsymbol{H}_{\mathrm{w}}$ 为动量轮角动量；卫星 ACS 所受总力矩 $\boldsymbol{M}_{\mathrm{q}}=\boldsymbol{M}_{\mathrm{c}}+\boldsymbol{M}_{\mathrm{d}}$。

1)卫星运行空间环境复杂，难以建立精确的干扰力矩 $\boldsymbol{M}_{\mathrm{d}}$ 模型。干扰动量轮对卫星 ACS 的控制力矩，从而影响系统输出。

2)反作用飞轮作为典型的卫星姿态控制部件，已经成为控制系统不可缺少的配置。但由于

http://bhxb.buaa.edu.cn

飞轮在进行姿态调整过程中，非线性摩擦、电机噪声以及轴承噪声等多种未知因素会带来控制中的不确定干扰力矩，难以精确 $\boldsymbol{M}_{\delta}$ 的模型。

3)执行机构发生故障时，其表现主要为执行机构的实际输出力矩会产生偏差 $\boldsymbol{M}_{\mathrm{f}}$，通过动力学与运动学方程，影响传感器测量输出 $\boldsymbol{\omega}_{\mathrm{o}}$ 与 $\boldsymbol{q}_{\mathrm{o}}$。而传感器发生故障时，会通过叠加故障值 $\boldsymbol{f}_{\mathrm{s}}$，通过 ACS 闭环影响控制器的指令输出力矩 $\boldsymbol{M}_{\mathrm{c}}$。ACS 中执行机构与传感器故障在系统中传播和相互影响，给故障诊断和辨识带来了困难和挑战。

综上所述，由于卫星空间环境干扰 $\boldsymbol{M}_{\mathrm{d}}$ 和飞轮的非线性以及噪声 $\boldsymbol{M}_{\delta}$ 的存在，卫星 ACS 难以用准确的模型描述，其传感器故障模型 $\boldsymbol{f}_{\mathrm{s}}$ 和执行机构故障模型 $\boldsymbol{f}_{\mathrm{a}}$ 识别困难。基于数据驱动的智能模式识别方法的发展，为此提供了一条有效途径。通过采集卫星 ACS 闭环系统的执行机构与传感器运行数据、以及控制系统中的指令信息，利用智能方法的泛化和学习能力，可实现 ACS 闭环系统的故障识别问题。

2 卫星 ACS 执行机构和传感器故障识别策略

深度森林算法是在深度学习理论以及深度神经网络的启发下，以随机森林(Random Forest，RF)算法为基础的一种有监督机器集成学习算法[18-20]。基于深度森林算法的卫星 ACS 执行机构和传感器故障识别策略如图 2 所示。首先，采集卫星 ACS 测试数据构建数据特征集；然后结合卫星 ACS 姿态动力学和运动学的分析，对数据特征集进行特征选择以及特征提取；最后通过深度森林算法建立的卫星 ACS 正常和故障模型对输入特征预测分类结果，实现卫星 ACS 执行机构与传感器的故障识别。

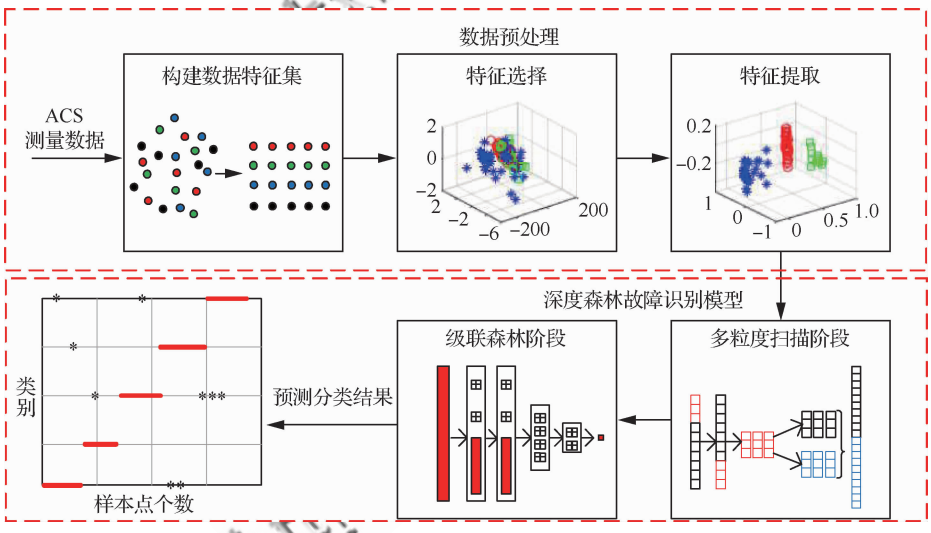


图 2 卫星 ACS 故障识别策略

Fig. 2 Fault identification strategy of satellite attitude control systems

3 特征提取与识别方法

3.1 构建原始特征集

记控制指令力矩为 $\boldsymbol{M}_{\mathrm{c}}$、动量轮指令转速增量为 $\Delta\boldsymbol{n}_{\mathrm{c}}$、动量轮实际转速为 $\boldsymbol{n}_{\mathrm{s}}$，当前控制周期下动量轮转速的期望增量为 $\Delta\boldsymbol{n}_{\mathrm{c}}$。

ACS 飞轮采用无刷直流电机控制，其电机的力矩平衡方程为

$$\boldsymbol{M}_{\mathrm{s}} = \boldsymbol{J}_{\mathrm{w}} \frac{\mathrm{d}\boldsymbol{\omega}_{\mathrm{w}}}{\mathrm{d}t} \tag{5}$$

式中：$\boldsymbol{M}_{\mathrm{s}}$ 为动量轮实际输出力矩；$\boldsymbol{\omega}_{\mathrm{w}}$ 为动量轮角速度(rad/s)；$\boldsymbol{J}_{\mathrm{w}}$ 为动量轮的转动惯量。记

$$\boldsymbol{M}_{\mathrm{s}} = \boldsymbol{K}\Delta\boldsymbol{n}_{\mathrm{s}} \tag{6}$$

其中：$\Delta\boldsymbol{n}_{\mathrm{s}}$ 为动量轮实际转速增量；$\boldsymbol{K} = \dfrac{\boldsymbol{J}\pi}{30\Delta T}$，为常值；$\Delta T$ 为 ACS 的控制周期。由式(6)可得

$\boldsymbol{M}_s$ 与 $\Delta\boldsymbol{n}_s$ 成线性关系，因此动量轮指令控制力矩 $\boldsymbol{M}_c$ 与动量轮指令转速增量 $\Delta\boldsymbol{n}_c$ 也成线性关系，即

$$\boldsymbol{M}_c = \boldsymbol{K}\Delta\boldsymbol{n}_c \tag{7}$$

由于动量轮指令转速增量 $\Delta\boldsymbol{n}_c$ 反映了飞轮的力矩输出情况，所以将其选择为系统状态空间的特征。

考虑到动量轮存在非线性摩擦力矩以及电机噪声力矩、轴承噪声力矩等不确定干扰力矩，令这些干扰力矩之和为 $\boldsymbol{M}_\delta$，则动量轮指令控制力矩 $\boldsymbol{M}_c$ 与实际控制力矩 $\boldsymbol{M}_s$ 之间的关系可以表示为

$$\boldsymbol{M}_s = \boldsymbol{M}_c + \boldsymbol{M}_\delta + \boldsymbol{f}_a \tag{8}$$

式中：$\boldsymbol{f}_a$ 为执行机构故障产生的偏差力矩，当执行机构无故障时，其值为 0。

令当前控制周期动量轮实际转速增量 $\Delta\boldsymbol{n}_s$ 与指令转速增量 $\Delta\boldsymbol{n}_c$ 的差值为 $\Delta\boldsymbol{r}_n$，其表达式为 $\Delta\boldsymbol{r}_n = \Delta\boldsymbol{n}_s - \Delta\boldsymbol{n}_c$，结合式(6)～式(8)可得

$$\Delta\boldsymbol{r}_n = \frac{1}{\boldsymbol{K}}(\boldsymbol{M}_\delta + \boldsymbol{f}_a) \tag{9}$$

当执行机构无故障时，$\Delta\boldsymbol{r}_n = \frac{1}{\boldsymbol{K}}\boldsymbol{M}_\delta$。而当执行机构发生故障时，$\boldsymbol{f}_a$ 会在不同故障模式下呈现出不同的变化特点，故 $\Delta\boldsymbol{r}_n$ 可作为反映状态模式空间的原始特征之一。

令 $\Delta\theta$ 为当前控制周期气浮台姿态角 θ 的增量，$\Delta\omega_z$ 为当前控制周期气浮台沿 z 轴旋转的角速度 ω_z 的增量。由上述分析可知，执行机构故障和传感器故障会使 Δr_n、Δn_c、$\Delta\theta$ 和 $\Delta\omega_z$ 发生变化，且这些变量在不同的故障模式下会有不同的变化特点。故本文选取 $\boldsymbol{\Phi} = [\Delta r_n, \Delta n_c, \Delta\theta, \Delta\omega_z]$ 作为反映状态模式空间的特征集。

以上构建的 ACS 无故障时的数据原始特征集记为 $\boldsymbol{\Phi}_h$，在故障模式 f_1 和 f_2 下的数据特征集记为 $\boldsymbol{\Phi}_{f_1}$ 和 $\boldsymbol{\Phi}_{f_2}$，其特征点的空间分布如图 3 所示。

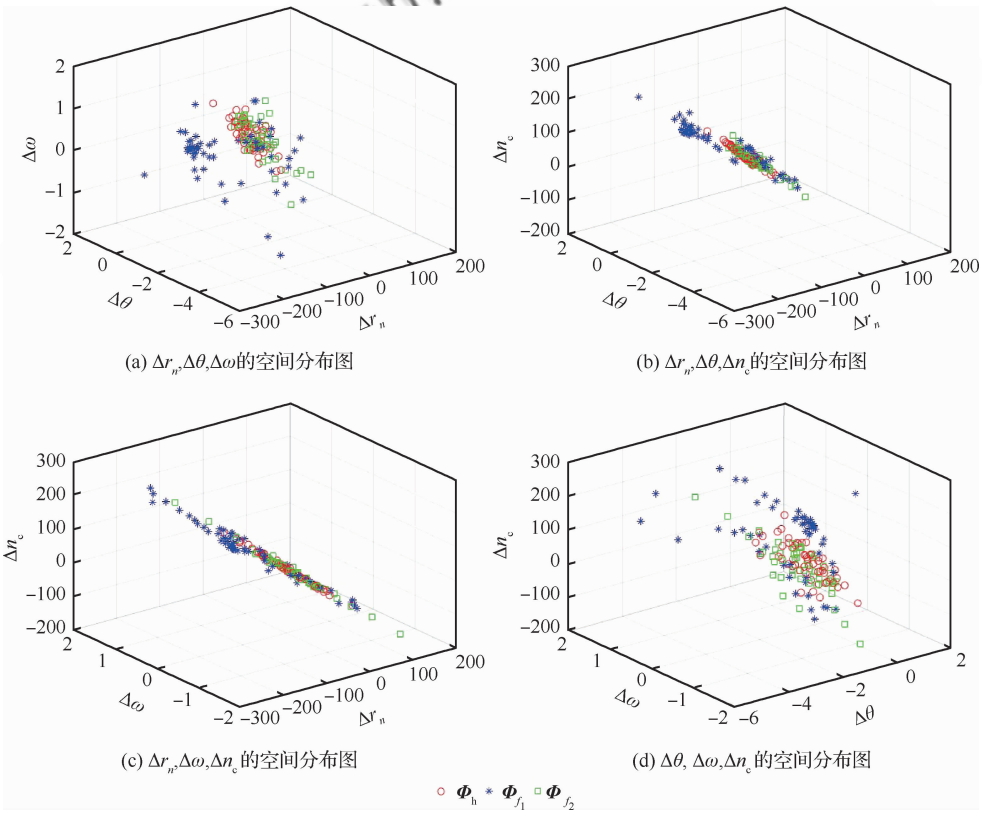


图 3 $\boldsymbol{\Phi}_{f_1}$、$\boldsymbol{\Phi}_{f_2}$ 和 $\boldsymbol{\Phi}_h$ 的原始特征点空间分布

Fig. 3 Spatial distribution of original feature points of $\boldsymbol{\Phi}_{f_1}$, $\boldsymbol{\Phi}_{f_2}$ and $\boldsymbol{\Phi}_h$

3.2 故障特征提取

特征提取是指提取数据的主要特征，除去数据中包含的冗余信息和错误信息，使得数据的特征更加明显。因为卫星遥测数据的高维性，以及传输过程的损耗，为了进行故障识别有必要进行

特征提取。

由图 3 可以看出，$\boldsymbol{\Phi}_{\mathrm{h}}$ 和 $\boldsymbol{\Phi}_{f_2}$ 的分布较为集中，$\boldsymbol{\Phi}_{f_1}$ 分布较为分散，但三者相互之间都有较大的交集，如果直接将原始特征数据集作为输入，训练深度森林以建立故障模式预测分类模型，将影响其分类精度。因此数据特征集 $\boldsymbol{\Phi}$ 进行故障特征提取。

以正常和故障时的 Δr_n 为例来分析故障对特征集 $\boldsymbol{\Phi}$ 产生的影响，如图 4 所示，t 为时间。对比图 4(a)和图 4(b)可以看出，ACS 故障情况下 Δr_n 的值整体上升，奇异性成分增多且波动程度增大。图 5 给出了不同故障类型下 Δr_n 曲线图。

特征选择方法，不仅要反映出信号的短期的突发特性与变化幅值，还要能反映出信号长期的趋势和统计特性，从而准确区分正常情况与故障情况、以及不同故障模型。

通过分析 ACS 原始特征集的数据特性，本文经过特征选择后建立的特征集为 $\boldsymbol{\Phi}$。其中，均值 μ、方差 σ^2 能很好地体现信号的统计学特性，而信息熵 H 和信号积分 I 能分别体现信号的变化剧烈程度和变化趋势，计算公式为

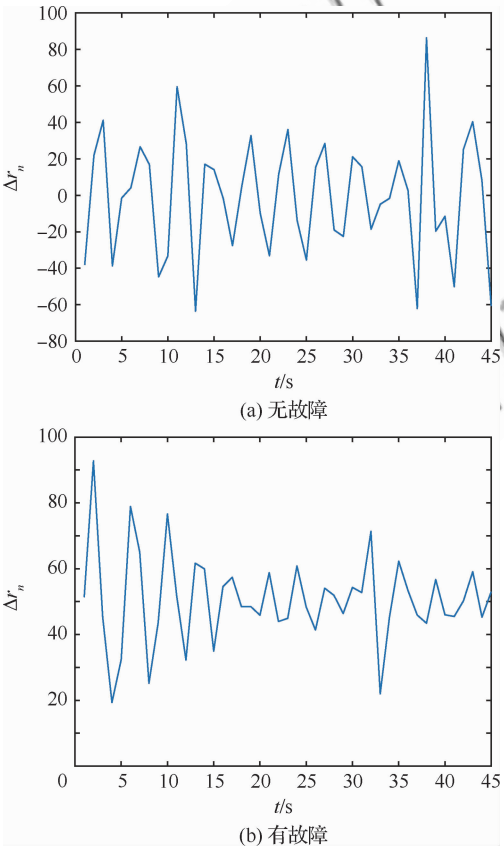


图 4 Δr_n 的曲线图

Fig. 4 Graph of Δr_n

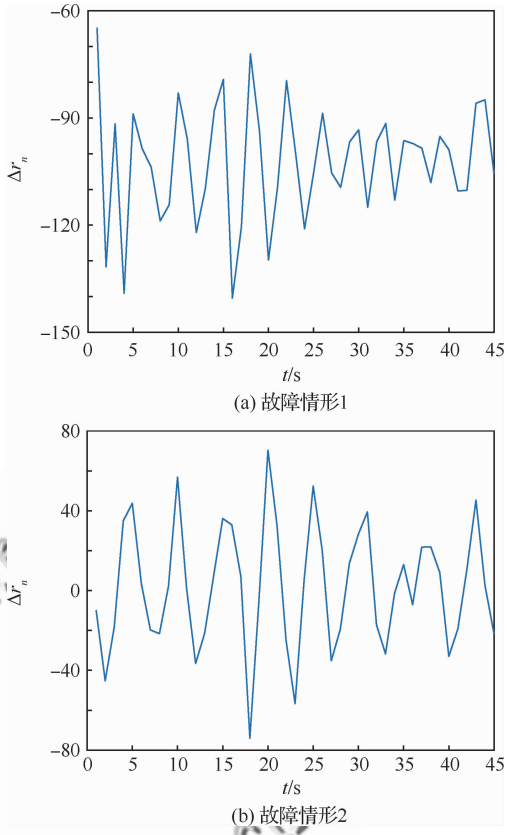


图 5 不同故障情况下的 Δr_n 曲线图

Fig. 5 Graphs of Δr_n under different fault conditions

$$\begin{cases} \mu = \dfrac{1}{N}\displaystyle\sum_{i=1}^{N} v_i \quad i = 1,2,\cdots,N \\ \sigma^2 = \dfrac{1}{N-1}\displaystyle\sum_{i=1}^{N}(v_i-\mu)^2 \quad i = 1,2,\cdots,N \\ H = -\displaystyle\sum_{k=1}^{c} p_k \log_2 p_k \quad k = 1,2,\cdots,c \\ I = \displaystyle\int v(t)\,\mathrm{d}t \end{cases} \tag{10}$$

式中：v 为信号幅值；N 为样本个数；c 为样本类别数；p_k 为第 k 类样本在总样本中所占的比例。

综合以上 4 个特征指标，对每个子窗口内的所有数据点，计算特征集 $\boldsymbol{\Phi}$ 中各个特征分量的均值 $\boldsymbol{\Phi}_1$，其中包含 $\mu_{\Delta r_n}$，$\mu_{\Delta n_c}$，$\mu_{\Delta\theta}$，$\mu_{\Delta\omega_z}$；方差 $\boldsymbol{\Phi}_2$ 包含 $\sigma^2_{\Delta r_n}$，$\sigma^2_{\Delta n_c}$，$\sigma^2_{\Delta\theta}$，$\sigma^2_{\Delta\omega_z}$；信息熵 $\boldsymbol{\Phi}_3$ 包含 $H_{\Delta r_n}$，$H_{\Delta n_c}$，$H_{\Delta\theta}$，$H_{\Delta\omega_z}$；积分 $\boldsymbol{\Phi}_4$ 包含 $I_{\Delta r_n}$，$I_{\Delta n_c}$，$I_{\Delta\theta}$，$I_{\Delta\omega_z}$；由 $\boldsymbol{\Phi}_1$，$\boldsymbol{\Phi}_2$，$\boldsymbol{\Phi}_3$，$\boldsymbol{\Phi}_4$ 组成新的特征集 $\boldsymbol{\Phi}'$。

在故障模式 f_1 和 f_2 情形下，新构建的特征集 $\boldsymbol{\Phi}'_{f_1}$ 和 $\boldsymbol{\Phi}'_{f_2}$ 如图 6 所示。

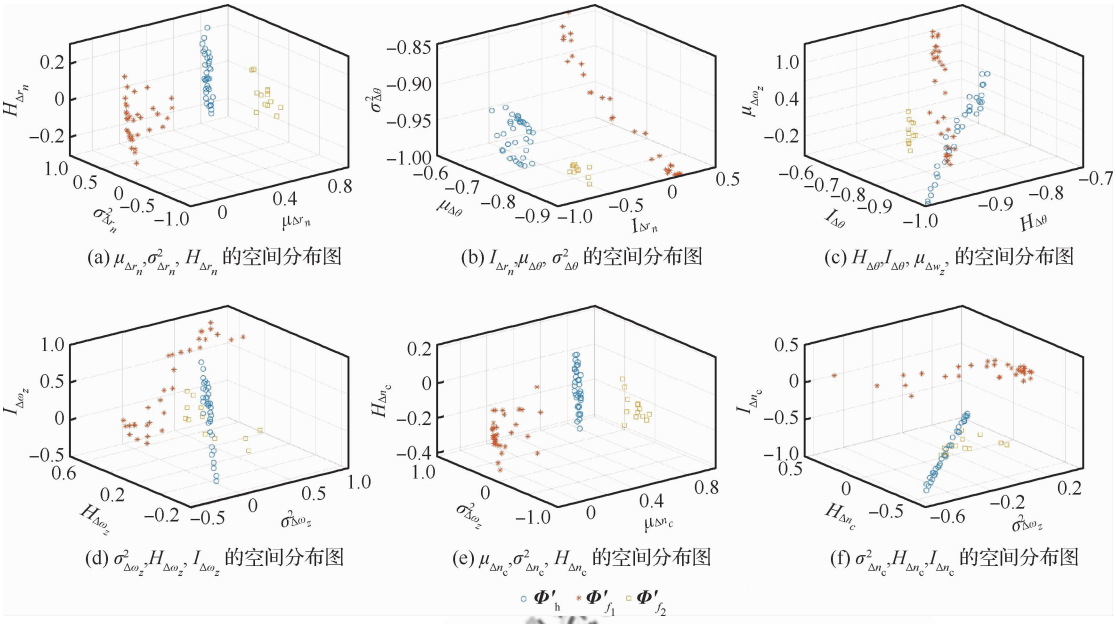


图 6 $\boldsymbol{\Phi}'_{f_1}$、$\boldsymbol{\Phi}'_{f_2}$ 和 $\boldsymbol{\Phi}'_h$ 的特征点空间分布

Fig. 6 Spatial distribution of feature points of $\boldsymbol{\Phi}'_{f_1}$, $\boldsymbol{\Phi}'_{f_2}$ and $\boldsymbol{\Phi}'_h$

由图 6 可以看出，$\boldsymbol{\Phi}'_{f_1}$、$\boldsymbol{\Phi}'_{f_2}$ 和 $\boldsymbol{\Phi}'_h$ 在三维空间中相互之间的交集明显减小，经过特征选择处理后，特征更加明显，有利于深度森林建立准确的预测分类模型。

构造的基于深度森林的卫星 ACS 执行机构与传感器故障识别预测分类模型如图 7 所示。

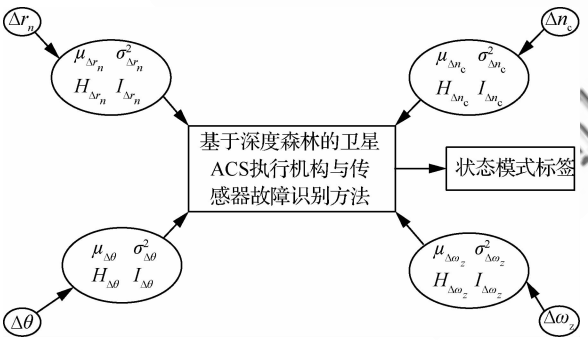


图 7 基于深度森林的卫星 ACS 执行机构与传感器故障识别预测分类模型

Fig. 7 Fault recognition prediction and classification model of actuators and sensors in satellite ACS based on deep forest algorithm

3.3 深度森林故障识别方法

深度森林算法是在深度学习理论以及深度神经网络的启发下，以随机森林算法为基础的一种有监督机器集成学习算法。作为一种具有一定深度的基于决策树的预测算法，深度森林算法将预测过程分为 2 个阶段：多粒度扫描阶段(multi-grained scanning)和级联森林阶段(cascade forest)，如图 8 所示，以下将依次对多粒度扫描阶段和级联森林阶段进行分析。

为提高深度森林算法中级联森林阶段的预测效果，深度森林算法设置了多粒度扫描阶段来对样本特征进行提取，尽可能地挖掘序列数据特征的顺序关系；通过设置级联森林阶段，以体现其深度学习的过程。级联森林阶段的每一级都由多个不同类型的森林模型组成。深度森林算法利用级联森林阶段对数据特性逐层进行处理，加强了算法的表征学习能力，有利于提高预测精准度。

基于深度森林的卫星 ACS 执行机构与传感器故障识别方法的流程如图 9 所示，整体流程分为训练和测试 2 个阶段，具体步骤如下：

1) 训练阶段

步骤 1 建立 ACS 训练样本集，并对样本数据进行预处理。

步骤 2 根据 ACS 正常和故障样本数据的特点，对训练样本进行特征选择和特征提取，得到训练样本集的特征数据。

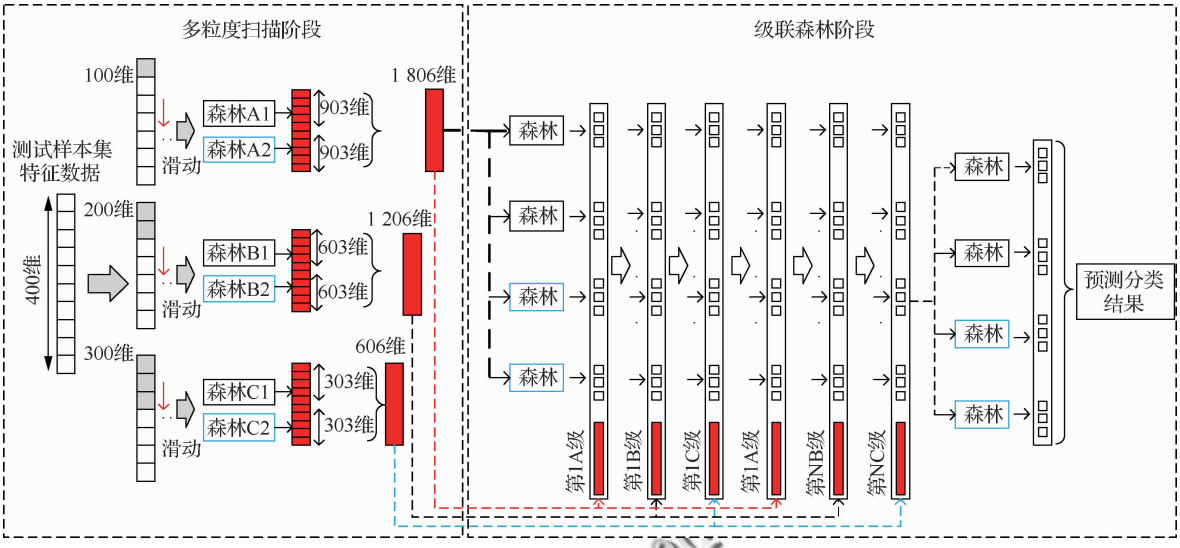


图 8 深度森林算法整体预测过程

Fig. 8 Whole prediction process of deep forest algorithm

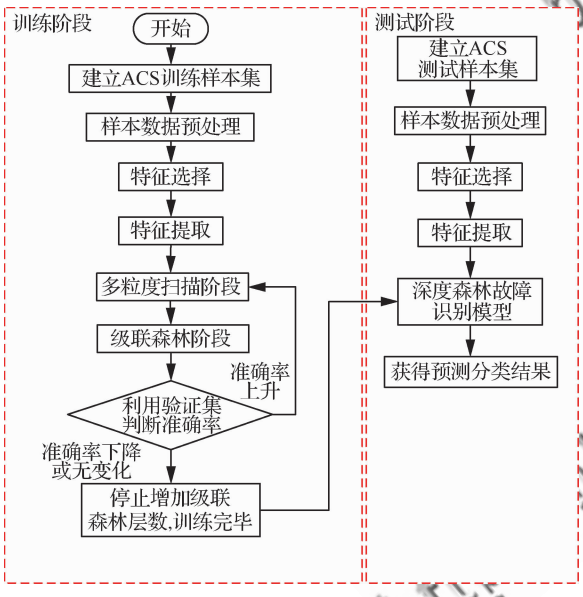


图 9 基于深度森林的卫星 ACS 执行机构与传感器故障识别流程

Fig. 9 Flow chart of fault identification of sensor and actuator satellite ACS based on deep forest algorithm

步骤 3 利用训练样本集的特征数据对深度森林进行训练。按照深度森林算法的超参数设置,对多粒度扫描阶段和级联森林阶段中的森林模型进行构造,确定级联森林的级数,并生成深度森林故障识别模型。

2) 测试阶段

步骤 1 建立 ACS 测试样本集,并对样本数据进行预处理。

步骤 2 采用训练样本的特征选择与特征提取方法处理测试样本,得到测试样本集的特征数据。

步骤 3 利用深度森林故障识别模型对测试样本集的特征数据进行预测,得到预测分类结果。

4 仿真试验及结果分析

4.1 试验平台介绍

本文开展了半物理仿真试验以验证所提方法的有效性。基于大理石平台的半物理仿真试验如图10所示,卫星模拟器的系统组成示意图

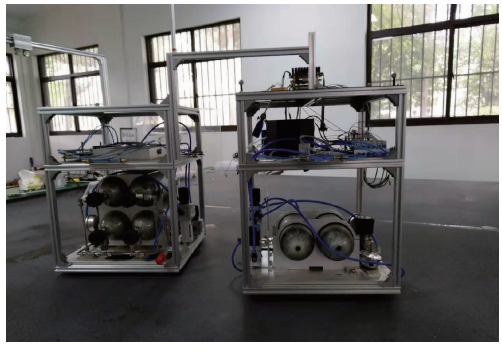


图 10 某卫星半物理仿真平台示意图

Fig. 10 Schematic diagram of satellite semi-physical simulation platform

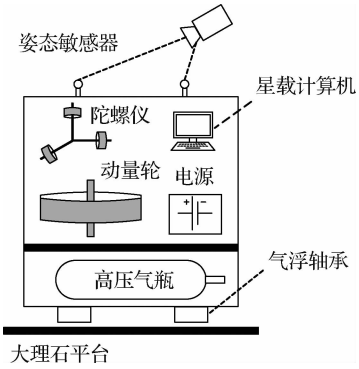


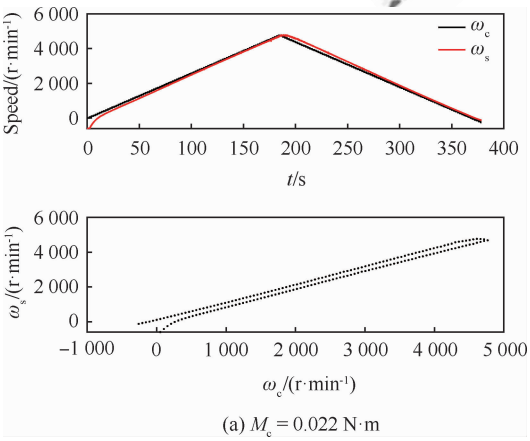
图 11 某卫星半物理仿真平台系统组成示意图[21]

Fig. 11 Composition of satellite semi-physical simulation platform system[21]

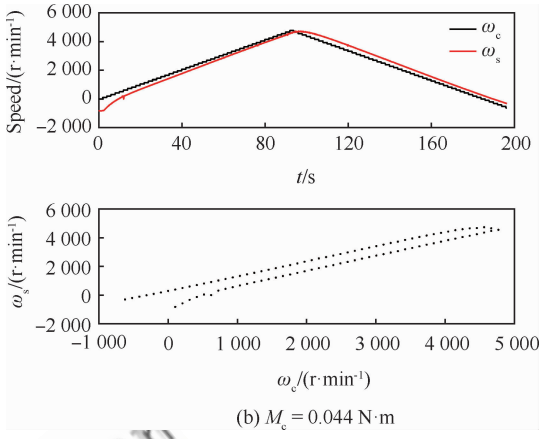
如图 11 所示[21]。

气浮台卫星 ACS 模拟系统主要包括控制器(星载计算机)、执行机构和传感器 3 个部分。星载计算机,通过姿态敏感器反馈的当前气浮台姿态信息,结合地面计算机发来的指令以及星载计算机内的控制算法对执行机构施加控制指令;执行机构为反作用飞轮,通过驱动电路输出的电压对气浮台产生相应的控制力矩。传感器包括姿态敏感器和陀螺仪,姿态敏感器用来实时获取当前气浮台的姿态信息,陀螺仪用来实时获取当前气浮台角速度。

试验所用飞轮的输入输出特性如图 12 所示。由图 12 可看出,飞轮存在物理受限特性及间隙特性,在试验中,将影响指令力矩与实际输出力矩的一致性,从而影响到闭环的控制状态,对执行机构和传感器故障的辨识提出了挑战。



(a) $M_c = 0.022$ N·m



(b) $M_c = 0.044$ N·m

图 12 不同指令力矩下的飞轮输出特性曲线

Fig. 12 Flywheel output characteristic curves under different command torques

4.2 故障模式设置

由于动量轮中的电机转子需要长时间连续不断地做机械运动,因此比较容易发生故障。动量轮的主要故障有动量轮卡死故障、空转故障、驱动电路故障、增益下降故障、摩擦力矩增大故障。其中动量轮卡死故障和空转故障,会对气浮台姿态机动及稳定造成比较大的影响,故障特征明显;摩擦力矩增大故障发生的主要原因包括轴承温度增高、轴承润滑不好、轴承保持架不稳定、壳体泄露导致内部真空环境密封失效、飞轮压力降低,而这些事件发生的概率很小,不考虑其故障情形。

传感器故障主要有卡死故障、偏差故障和噪声故障 3 种故障模式。其中传感器卡死故障的故障特征明显,易于故障识别,且传感器噪声故障发生的概率相对较大。故障模式如表 1 所示。表中:f_1 为动量轮驱动电路故障;f_2 为动量轮增益下降故障;f_3 为动量轮间隙故障;f_4 为陀螺仪噪声故障;f_5 为姿态敏感器噪声故障。n_o 为动量轮实际输出转速;n_i 为动量轮理论输出转速;K_1 为动量轮驱动电路故障增益系数,$0 < K_1 < 1$。M_o 为动量轮实际输出力矩;M_i 为动量轮理论输出力矩;K_2 为动量轮增益下降故障增益系数,$0 < K_2 < 1$。$\delta(t)$ 为动量轮故障信号;Δt 为故障持续时间;ω_o 为陀螺仪实际输出;ω_i 为陀螺仪理论输出;ω_f 为陀螺仪故障信号。θ_o 为姿态敏感器实际输出;θ_i 为姿态敏感器理论输出;θ_f 为姿态敏感器故

http://bzxb.buaa.edu.cn
http://bzxb.buaa.edu.cn

表 1 执行机构与传感器故障模式

Table 1 Fault mode of actuators and sensors

故障类别	故障数学模型	故障原因
f_1	$n_o(t)=\begin{cases} n_i(t) & t<t_f \\ K_1 n_i(t) & t\geqslant t_f \end{cases}, K_1<1$	驱动电路放大器故障
f_2	$M_o(t)=\begin{cases} M_i(t) & t<t_f \\ K_2 M_i(t) & t\geqslant t_f \end{cases}, K_2<1$	驱动电机故障、由于温度的变化，元器件老化等因素
f_3	$M_o(t)=\begin{cases} M_i(t) & t<t_f \\ M_i(t)+\delta(t) & t_f\leqslant t\leqslant t_f+\Delta t \\ M_i(t) & t>t_f \end{cases}$	总线电压故障或是电机存在间歇的时变故障
f_4	$\omega_o(t)=\begin{cases} \omega_i(t) & t<t_f \\ \omega_i(t)+\omega_f(t) & t\geqslant t_f \end{cases}$	陀螺线路盒电压输出不稳，测量噪声增大
f_5	$\theta_o(t)=\begin{cases} \theta_i(t) & t<t_f \\ \theta_i(t)+\theta_f(t) & t\geqslant t_f \end{cases}$	存在干扰目标，CCD出现瑕疵点

障信号；t_f 为故障发生时刻。

4.3 故障定位结果及分析

本文采用保持法对深度森林故障识别模型进行准确性评估，即随机选择70%的原始数据集作为训练集，30%的原始数据集作为测试集。

先将训练集进行数据预处理、特征选择、特征提取，并贴上相应类别标签后输入到深度森林中进行模型训练，随后利用深度森林故障识别模型对测试集的特征点进行分类，判别每个特征点所属状态模式。图13给出所建立的深度森林故障识别模型对某一组测试集的故障识别结果，其中 f_0 为卫星 ACS 无故障。

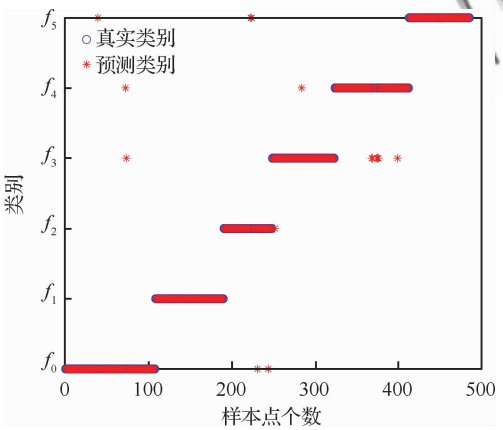


图 13 深度森林故障识别模型对某一组测试集的故障识别结果

Fig. 13 Fault identification results of one test set of deep forest algorithm

从图13可以看出，深度森林故障识别模型可实现绝大部分特征点的类别预测，但仍有少部分特征点出现了误判。针对正常和故障采样数据重复多次随机划分训练集和测试集，并对深度森林故障识别模型的识别结果进行统计，得到深度森林故障识别模型预测类别对真实类别的识别准确率如表2所示，此处的识别准确率表示当样本特征点的真实类别为 $f_i(i=0,1,\cdots,5)$ 时，深度森林故障识别模型的预测类别为 $f_j(j=0,1,\cdots 5)$ 的概率。

对每种状态模式的识别准确率均达到96.33%，如表2所示。

从表2中可以看出：① 故障 f_3 与故障 f_4 有少部分特征点出现了相互误判。这是因为 f_3 属于动量轮间隙故障，主要通过在一段时间内产生不定大小的动量轮故障偏差力矩 $\delta(t)$，从而影响姿态角 θ 和角速度 ω_z 的输出；② f_4 属于陀螺仪噪声故障，主要通过产生不确定的角速度偏差 $\omega_f(t)$，从而通过闭环回路影响下一周期的系统输出。两者的故障信号都具有一定的随机性，使得两者在故障特征空间上存在一定的交集。当两者在故障特征空间上相交时，造成误判的发生。

从仿真结果看，本文提出的深度森林故障识别模型具有较高的泛化能力，同时也验证了深度森林算法应用于卫星 ACS 执行机构与传感器故障识别的有效性。

表 2 深度森林故障识别模型预测类别对真实类别的识别准确率

Table 2 Accuracy rates of predicted category by deep forest fault recognition model to real category

预测类别	识别准确率/%					
	f_0	f_1	f_2	f_3	f_4	f_5
f_0	98.15	0	0	1.23	0	0
f_1	0	100	0	0	0	0
f_2	0	0	96.55	0	0	0.42
f_3	1.85	0	0	96.33	2.25	0.95
f_4	0	0	1.65	1.09	97.75	0
f_5	0	0	1.8	1.35	0	98.63

5 结 论

本文将深度森林算法应用于卫星 ACS 执行机构与传感器的故障识别。通过从少量卫星信号数据中提取能反映故障模式特征的信号特征，借助深度森林算法实现由故障特征参量空间向故障模式空间的映射，从而识别故障模式。通过某卫星半物理仿真平台试验，在气浮台干扰力矩、卫星转动惯量未知、飞轮非线性特性、闭环故障传播等多种不定因素影响下，深度森林算法的预测分类准确性达到了 96.33%，可有效地实现卫星 ACS 执行机构与传感器的故障识别。

参 考 文 献

[1] 王巍，宝音贺喜格，姜兴渭，等. 基于状态观测器的卫星执行机构故障诊断方法研究[J]. 黑龙江自动化技术与应用，1999(4)：9-12.
WANG W，BAOYIN H X G，JIANG X W，et al. Fault diagnosis method of actuators in satellite based on state observer[J]. Techniques of Automation and Applications，1999(4)：9-12 (in Chinese).

[2] LI C L，CHEN X Q，JIA Q X，et al. FDD of the attitude control system of satellite with actuator fault and time delay via two-stage Kalman filter[C]// 3rd International Conference on Machinery Electronics and Control Engineering，2014，441：859-863.

[3] 江文建，姜斌，廖鹤，等. 基于 ILLE 和 SVM 的卫星执行机构系统故障检测与定位[J]. 航天控制，2019(3)：4.
JIANG W J，JIANG B，LIAO H，et al. Fault detection and location of actuator system in satellite based on ILLE and SVM[J]. Aerospace Control，2019 (3)：4 (in Chinese).

[4] 胡志坤，孙岩，姜斌，等. 一种基于最优未知输入观测器的故障诊断方法[J]. 自动化学报，2013，39(8)：1225-1230.
HU Z K，SUN Y，JIANG B，et al. An optimal unknown input observer based fault diagnosis method[J]. Acta Automatica Sinica，2013，39(8)：1225-1230 (in Chinese).

[5] 樊雯，程月华，姜斌. 基于模糊滑模的卫星姿态控制系统故障诊断[J]. 东南大学学报(自然科学版)，2010，40(S1)：238-243.
FAN W，CHENG Y H，JIANG B. Fault diagnosis in attitude control system of satellite based on fuzzy sliding mode [J]. Journal of Southeast University (Natural Science Edition)，2010，40(S1)：238-243 (in Chinese).

[6] NADERI E，KHORASANI K. A data-driven approach to actuator and sensor fault detection，isolation and estimation in discrete-time linear systems[J]. Automatica，2017，85：165-178.

[7] WANG K，CHEN J，SONG Z. Concurrent fault detection and anomaly location in closed-loop dynamic systems with measured disturbances[J]. IEEE Transactions on Automation Science and Engineering，2018.

[8] CHENG Y，JIANG B，LU N，et al. Incremental locally linear embedding-based fault detection for satellite attitude control systems[J]. Journal of the Franklin Institute，2016，353(1)：17-36.

[9] 李磊，高永明，吴止锾，等. 基于神经网络观测器的卫星姿态控制系统陀螺故障诊断[J]. 计算机测量与控制，2018，26(11)：7-11.
LI L，GAO Y M，WU Z H，et al. Gyroscopic fault diagnosis method for satellite attitude control system based on neural network observer[J]. Computer Measurement & Control，2018，26(11)：7-11 (in Chinese).

[10] MOUSAVI S，KHORASANI K. Fault detection of reaction wheels in attitude control subsystem of formation flying satellites：A dynamic neural network-based approach [J]. International Journal of Intelligent Unmanned Systems，2014，2(1)：2-26.

[11] 陈辛，魏炳翌，闻新. 基于支持向量机的卫星执行机构故障诊断研究[J]. 中国空间科学技术，2018，38(2)：47-55.
CHEN X，WEI B Y，WEN X. Study of support vector machine based faults diagnosis for satellite's actuators[J]. Chinese Space Science and Technology，2018，38(2)：47-55 (in Chinese).

[12] JEGADEESHWARAN R，SUGUMARAN V. Fault diagnosis of automobile hydraulic brake system using statistical features and support vector machines[J]. Mechanical Systems and Signal Processing，2015，52：436-446.

[13] CERRADA M，ZURITA G，CABRERA D，et al. Fault diagnosis in spur gears based on genetic algorithm and random forest[J]. Mechanical Systems and Signal Processing，2016，70：87-103.

[14] GRAVES A，MOHAMED A，HINTON G. Speech recognition with deep recurrent neural networks[C]// 2013 IEEE International Conference on Acoustics，Speech and Signal Processing. Piscataway：IEEE Press，2013：6645-6649.

[15] ZHOU Z H，FENG J. Deep forest：Towards an alternative to deep neural networks. arXiv 2017[J]. arXiv preprint arXiv：1702. 08835.

[16] 陈吕鹏，殷林飞，余涛，等. 基于深度森林算法的电力系统短期负荷预测[J]. 电力建设，2018，39(11)：42-50.
CHEN L P，YIN L F，YU T，et al. Short-term power load forecasting based on deep forest algorithm [J]. Electric Power Construction，2018，39(11)：42-50 (in

http://hbxb.buaa.edu.cn
http://hkzb.buaa.edu.cn

Chinese).

[17] HU G, LI H, XIA Y, et al. A deep Boltzmann machine and multi-grained scanning forest ensemble collaborative method and its application to industrial fault diagnosis[J]. Computers in Industry, 2018, 100: 287-296.

[18] 沈文博, 孙荣霞, 马少卿, 等. 深度森林与人工神经网络在光伏出力预测的比较[J]. 信息技术与网络安全, 2018, 37(4): 49-51.
SHEN W B, SUN R X, MA S Q, et al. Comparison of deep forest and artificial neural network in prediction of PV output[J]. Information Technology and Network Security, 2018, 37(4): 49-51(in Chinese).

[19] LI M, ZHANG N, PAN B, et al. Hyperspectral image classification based on deep forest and spectral-spatial cooperative feature[C]// International Conference on Image and Graphics. Berlin: Springer, 2017: 325-336.

[20] UTKIN L V, KOVALEV M S, MELDO A A. A deep forest classifier with weights of class probability distribution subsets[J]. Knowledge-Based Systems, 2019, 173: 15-27.

[21] 康国华, 杨炳辉, 刘瑶, 等. 基于微小卫星编队的聚光操控技术[J]. 航天控制, 2018, 36(2): 42-47.
KANG G H, YANG B H, LIU Y, et al. The technology of light control based on small satellite formation[J]. Aerospace Control, 2018, 36(2): 42-47 (in Chinese).

(责任编辑: 苏磊,张晗)

Fault identification of actuators and sensors of satellite attitude control systems based on deep forest algorithm

CHENG Yuehua[1,*], JIANG Wenjian[1], YANG Hao[1], XUE Qi[1], LIAO He[2]

1. *School of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211100, China*
2. *School of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China*

Abstract: The difficulty in identifying the faulted sensors and actuators of satellite Attitude Control Systems (ACS) resides in the spreading of faults in the closed loop. The deep forest algorithm is introduced in this study to build a fault prediction model to achieve the isolation of the sensor faults and actuator faults. After collecting healthy ACS telemetry data to group a training set according to the dynamic characteristics of ACS, we apply appropriate feature selection and extraction methods to the training set, obtaining the features of both the sensor faults and actuator faults. The deep forest algorithm, with its strong generalization ability, is then used to learn and identify fault information, thereby establishing a fault prediction model to realize the recognition of actuator and sensor faults. The results of the semi-physical simulation indicate that the proposed method can identify the faults of sensors and actuators effectively in the presence of many uncertain factors, such as the interference moments of air bearing testbeds, unknown moments of the inertia of satellites, nonlinear characteristics of flywheels and fault propagation in the closed loop of ACS.

Keywords: deep forest algorithm; satellite attitude control systems; actuators; sensors; fault identification

Received: 2019-12-13; **Revised**: 2019-12-26; **Accepted**: 2019-12-31; **Published online**: 2020-01-03 13:53
URL: http://hkxb.buaa.edu.cn/CN/html/2020S120.html
Foundation items: National Key R&D Program of China (2016YFB0500803); Equipment Pre-research National Defense Science Technology Key Laboratory Foundation under Grant (1422080307)
* **Corresponding author**. E-mail: chengyuehua@nuaa.edu.cn