

深空探测航天器姿态控制系统故障定位

叶正宇¹, 程月华^{2†}, 韩笑冬³, 姜斌²

(1. 南京航空航天大学 航天学院, 江苏南京 211100; 2. 南京航空航天大学 自动化学院, 江苏南京 211100;
3. 中国空间技术研究院 通信卫星事业部, 北京 100830)

摘要: 执行机构与敏感器故障检测与定位是深空探测任务卫星平台可靠运行的前提和保障。本文从数据的角度出发, 结合姿控系统工作机理, 提出一种基于神经网络和支持向量机结合的故障诊断方法用于检测并定位故障。故障诊断方法分为3步, 首先采集姿控系统的状态信息, 采用神经网络对闭环姿控系统中未知动态特性建模并进行预测; 然后将姿控系统敏感器信号与神经网络预测输出比较生成残差并提取故障特征; 最后采用支持向量机辨识残差特征检测故障, 并结合运动学特性分析定位故障。仿真结果表明本文所提方法可以有效提取、辨识故障特征, 实现执行器与敏感器的故障检测定位。

关键词: 故障定位; 神经网络; 支持向量机; 姿态控制系统

引用格式: 叶正宇, 程月华, 韩笑冬, 等. 深空探测航天器姿态控制系统故障定位. 控制理论与应用, 2019, 36(12): 2093–2099

DOI: 10.7641/CTA.2019.90468

Fault location for attitude control systems of deep space exploration satellites

YE Zheng-yu¹, CHENG Yue-hua^{2†}, HAN Xiao-dong³, JIANG Bin²

(1. College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 211100, China;
2. College of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 211100, China;
3. Communications Satellite Division, China Academy of Space Technology, Beijing 100830, China)

Abstract: Fault detection and location is the prerequisite and guarantee for the reliability of the satellite for deep space exploration missions. Combined with the analysis of the attitude control system (ACS) mechanism, we present a data-driven fault diagnosis (FD) method based on neural networks and support vector machines (SVM) to detect and locate fault. The FD scheme is composed of 3 steps. Firstly, the sensor signals of the ACS are collected, and a neural network is applied to model the unknown dynamic characteristic of closed-loop ACS and make predictions; Then, ACS sensor signals are compared with the neural network predictions to generate residuals and extract the fault features; Finally, an SVM is applied to identify the fault features to realize fault detection. And combined with kinematic analysis, fault location is realized. The simulation results show that the proposed method can effectively extract and identify the fault features and is capable of realizing the fault detection and location of actuator and sensor.

Key words: fault location; neural networks; support vector machines; attitude control system

Citation: YE Zhengyu, CHENG Yuehua, HAN Xiaodong, et al. Fault location for attitude control systems of deep space exploration satellites. *Control Theory & Applications*, 2019, 36(12): 2093–2099

1 引言

深空探测航天器研发周期长、成本高, 而深空探测具有面临环境复杂、任务周期长以及任务多样化等特点, 提高星上控制系统可靠性和容错运行能力是深空

探测任务迫切而具有挑战性的研究重点。姿态控制系统(attitude control system, ACS)是卫星最关键的分系统之一, 却是卫星故障易发的分系统, 而一旦姿控系统发生故障, 将影响卫星任务执行效率, 严重时甚至

收稿日期: 2019-06-22; 录用日期: 2019-11-26。

†通信作者. E-mail: chengyuehua@nuaa.edu.cn; Tel.: +86 25-84896829.

本文责任编辑: 王大轶。

装备预研国防科技重点实验室基金项目(1422080307), 国家自然科学基金项目(61972398), “十三五”装备预先研究项目(30501050403), 研究生创新基地(实验室)开放基金项目(kfjj20180321)资助。

Supported by the Equipment Pre-research National Defense Science and Technology Key Laboratory Foundation (1422080307), the National Natural Science Foundation of China (61972398), the 13th Five-Year Equipment Pre-research Project (30501050403) and the Graduate Innovation Base (Lab) Open Foundation (kfjj20180321).

导致卫星失效^[1-4].

卫星姿控系统的闭环控制保证了系统对外部扰动和微小故障的鲁棒性, 却也决定了其故障会经由反馈在系统中传递扩散的特点^[5]. 对于闭环系统而言, 敏感器作为获取系统状态的主要部件, 其故障会为系统的监测、控制以及故障诊断带来严重的影响^[6].

由于卫星ACS系统闭环控制的特点, 执行器与敏感器故障往往难于区分. 针对ACS系统的故障检测定位问题, 国内外学者提出了许多解决方法, 主要通过提取ACS系统高维数据中包含的故障信息进行故障诊断^[7]. 文献[8]用NPCA对高维的卫星姿态敏感器数据进行降维以提取数据特征, 针对已有数据样本的 m 类故障设置 m 个支持向量机(support vector machines, SVM)进行数据辨识, 最后结合DS证据理论对故障类型进行推理. 其诊断的故障为已有数据样本的故障类型, 而实际航天中健全的故障数据样本库难以获取. 文献[9]使用神经网络(neural networks, NN)对卫星姿控系统进行建模, 与实际姿控系统陀螺仪输出比较生成残差, 并检验残差阈值进行故障检测. 该方法仅从动力学出发构造观测器, 未考虑姿控系统的运动学特性, 仅能检测故障而不能定位故障. 文献[10]中结合奇异摄动理论和几何方法对近地轨道卫星进行执行器和敏感器故障分离, 采集飞轮转速、星敏感器和陀螺仪信号, 构造多个观测器进行故障检测, 结合各个观测器检测结果定位故障. 该方法基于模型, 采用飞轮转速信号构造观测器, 并未对其他执行器进行讨论, 在一定程度上限制了该方法的普适性.

从调研结果看, 基于模型的方法其实用效能受建模精细程度限制, 基于数据的方法其诊断性能因未结合模型机理受限. 针对执行器与敏感器故障难于区分的问题, 本文结合卫星模型机理, 提出一种基于数据驱动的故障诊断(fault diagnosis, FD)方法, 采用NN预测输出与姿控系统敏感器信号生成残差, 对残差进行特征提取; 再结合动力学特性分析, 采用SVM辨识残差特征实现自主故障检测与故障定位.

2 问题描述

卫星姿控系统结构如图1所示: M_c 为控制器指令力矩, M_q 为执行器输出力矩, $\omega = (\omega_x \ \omega_y \ \omega_z)^T$ 和 $q = (q_1 \ q_2 \ q_3 \ q_4)^T$ 分别为角速度和四元数, ω_s 和 q_s 为敏感器测量值.

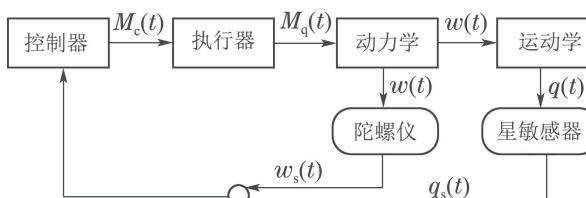


图 1 ACS系统结构框图

Fig. 1 ACS frame

卫星姿态动力学运动学微分方程如式(1)所示, 其中: J_{sat} 为卫星转动惯性矩阵, \odot 为四元数点乘. 记 ω_w 和 J_w 分别为飞轮的角速度和转动惯量, 则 $h_w = J_w \cdot \omega_w$ 为飞轮角动量.

记方程组(1)中下式为 $\dot{\omega} = f(M_q, \omega, h_w)$, M_c 为指令控制力矩. 理想情况下, 执行器无故障时有 $M_q = M_c$ 成立, 代入其中得 $\dot{\omega}_c = \dot{\omega} = f(M_q, \omega, h_w)$, 其中 $\dot{\omega}_c$ 为理想状态下的角速度微分量.

$$\left\{ \begin{array}{l} \dot{q} = \frac{1}{2}q \odot \omega = \\ \frac{1}{2} \begin{pmatrix} 0 & \omega_z & -\omega_y & \omega_x \\ -\omega_z & 0 & \omega_x & \omega_y \\ \omega_y & -\omega_x & 0 & \omega_z \\ -\omega_x & -\omega_y & -\omega_z & 0 \end{pmatrix} \begin{pmatrix} q_1 \\ q_2 \\ q_3 \\ q_4 \end{pmatrix}, \\ \dot{\omega} = J_{\text{sat}}^{-1}[M_q - \omega \times (J_{\text{sat}} \cdot \omega + h_w)]. \end{array} \right. \quad (1)$$

故障时, 有 $M_q \neq M_c$ 和 $h'_w \neq h_w$, 记 M_f 和 Δh_w 分别为故障引起的力矩偏差和飞轮角动量偏差. 除 M_f 外考虑扰动力矩 M_d , 将 $M_q = M_c + M_f + M_d$ 和 $h'_w = h_w + \Delta h_w$ 代入 $\dot{\omega} = f(M_q, \omega, h_w)$ 中, 可得

$$\begin{aligned} \dot{\omega} &= f(M_q, \omega, h_w) = \\ &f(M_c + M_f + M_d, \omega, h'_w) = \\ &J_{\text{sat}}^{-1}[(M_c + M_f + M_d) - \\ &\omega \times (J_{\text{sat}} \cdot \omega + h_w + \Delta h_w)] = \\ &f(M_c, \omega, h_w) + J_{\text{sat}}^{-1}(M_f + \omega \times \Delta h_w) + \\ &J_{\text{sat}}^{-1}M_d = \dot{\omega}_c + \dot{\omega}_f + \dot{\omega}_d, \end{aligned} \quad (2)$$

其中: $\dot{\omega}_c$ 为理想机动过程角速度微分量; $\dot{\omega}_f$ 和 $\dot{\omega}_d$ 分别为故障和扰动力矩引起的角速度微分量.

由于方程(2)难以获得 ω 的具体表达式, 且其具体表达式对本方法研究无意义, 为了方便后续讨论, 直接记 ω_c 为理想机动过程的角速度, $\Delta\omega_f$ 和 $\Delta\omega_d$ 分别为故障和扰动引起的角速度增量, 则实际角速度应为 $\omega = \omega_c + \Delta\omega_f + \Delta\omega_d$.

将 $\omega = \omega_c + \Delta\omega_f + \Delta\omega_d$ 代入式(1)中四元数微分方程, 有

$$\dot{q} = \frac{1}{2}q \odot \omega = \frac{1}{2}q \odot (\omega_c + \Delta\omega_f + \Delta\omega_d). \quad (3)$$

从式(2)和式(3)可以看出, 执行器故障和扰动力矩会通过影响动力学过程导致角速度 ω 异常, 进而影响运动学过程导致姿态 q 异常, 从而导致敏感器测量值 ω_s 和 q_s 异常. 而执行器输出 M_q 是通过敏感器测量值 ω_s 和 q_s 计算得到, 敏感器故障时会导致指令力矩 M_q 异常, 进而影响 M_q 异常. 可以看到, 闭环姿控系统中, 敏感器故障和执行器故障相互影响, 相互干扰, 最终扩散到整个姿控系统.

若仅使用敏感器所测的角速度 ω_s 和姿态角 q_s 进行故障诊断, 由于缺乏足够的冗余信息, 当其中一个敏感器故障时, 无法完成故障定位. 而姿控系统中执行器和敏感器都可能发生故障, 对故障定位研究更具挑

战性.

3 方案设计

针对姿控闭环系统中敏感器和执行器故障检测定位问题, 本文采用NN和SVM方法, 结合卫星姿态运动学分析, 利用敏感器测量数据完成自主故障定位.

设计故障诊断方法如图2所示, 使用NN预测输出与姿控系统敏感器信号比较生成残差, 然后SVM辨识残差特征进行故障检测, 最后结合运动学分析进行故障定位.

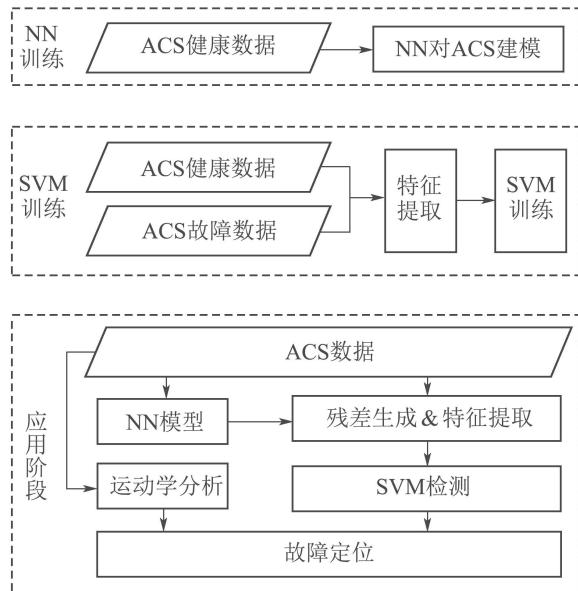


图 2 故障检测定位方案

Fig. 2 Fault detection and location scheme

由于NN和SVM需要经过训练才能使用, 所以方案设计分为2个阶段: 训练阶段和应用阶段. 训练阶段主要包括:

1) 采集无故障姿控系统姿态敏感器信号, 对NN模型进行训练, 以实现对姿控系统未知动态特性的建模;

2) 采集姿控系统无故障残差特征和故障残差特征对SVM模型进行训练, 使SVM能检测敏感器信号是否异常.

应用阶段主要包括:

1) 实时采集姿控系统姿态敏感器输出, 并与NN预测输出比较, 获得信号残差;

2) 星载计算机对残差进行在线特征提取;

3) 使用SVM根据残差特征自主辨识敏感器信号进行故障检测;

4) 根据SVM检测结果, 结合姿态运动学分析自主故障定位.

3.1 基于神经网络的姿控系统建模

NN是一种为了模仿动物神经网络行为而提出的分布式并行信息处理算法, 在隐层数(hidden layer)和

节点(node)足够多时, 可以实现对任意非线性函数的逼近^[11-12].

使用NN对姿控系统进行建模逼近. 记姿控系统角速度和姿态角的变化关系如式(4), 角速度更新部分为动力学, 姿态角更新部分为运动学. 其中: T_c 为卫星姿控系统控制周期, $\omega(t)$ 为 t 时刻 ω 的取值, $\omega(t+T_c)$ 为 $t+T_c$ 时刻 ω 的取值, 其他变量亦然. 从式(4)的输入可以看到, 动力学过程相对独立于运动学过程, 运动学过程却依赖于动力学过程:

$$\begin{cases} \omega(t+T_c) = f[M_c(t), \omega(t), \omega_w(t)], \\ q(t+T_c) = g[M_c(t), q(t), \omega(t)]. \end{cases} \quad (4)$$

NN对姿控系统未知动态的建模是对 $f(*)$ 和 $g(*)$ 进行逼近的过程, 而由于 $f(*)$ 和 $g(*)$ 的输入变量耦合较多, 若采用2个NN分别进行建模, 会增加大量节点和训练时间. 这里封装姿控系统执行器、动力学和运动学模块, 对整体使用单个NN进行建模, 如图3所示.

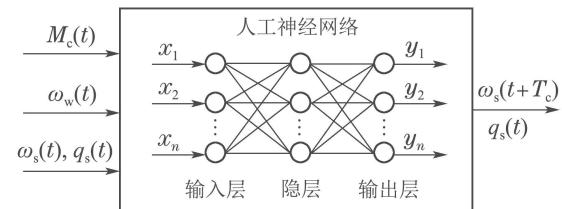


图 3 使用神经网络对 ACS 系统建模

Fig. 3 Modelling ACS with NN

由式(4)可知, 要对卫星动力学模块进行建模, 则NN输入样本应至少包括 M_c , ω_s 和 ω_w , 而由于实际卫星扰动力矩 M_d 与姿态有关, 所以输入样本还应包括 q_s . 采集无故障姿控系统的 M_c , ω_s , ω_w 和 q_s , 构造NN的输入样本 X 和输出样本 Y 如式(5)所示:

$$\begin{cases} X = (M_c(t) \ \omega_w(t) \ \omega_s(t) \ q_s(t))^T, \\ Y = (\omega_s(t+T_c) \ q_s(t+T_c))^T. \end{cases} \quad (5)$$

3.2 故障特征提取

记NN的姿态角和角速度输出为 q_{NN} 和 ω_{NN} , 则残差提取见式(6). 其中: r_q 和 r_ω 分别为姿态角和角速度残差, $r_q = (r_{q_1}, r_{q_2}, r_{q_3}, r_{q_4})$, $r_\omega = (r_{\omega_x}, r_{\omega_y}, r_{\omega_z})$. 四元数叉乘 $[q \otimes]$ 定义见式(7), 四元数求逆见式(8).

$$\begin{cases} r_q = q_s^{-1} \otimes q_{NN}, \\ r_\omega = \omega_s - \omega_{NN}. \end{cases} \quad (6)$$

获得传感器信号残差后, 通过计算残差的信息熵 H 、均值 μ 和标准差 σ^2 进行特征提取. 记 v 为残差 $r = (r_q \ r_\omega)^T$ 中任一维的分量, 则 v 的特征提取见式(9).

$$[q \otimes] = \begin{pmatrix} q_4 & q_3 & -q_2 & q_1 \\ -q_3 & q_4 & q_1 & q_2 \\ q_2 & -q_1 & q_4 & q_3 \\ -q_1 & -q_2 & -q_3 & q_4 \end{pmatrix}, \quad (7)$$

$$q^{-1} = \begin{pmatrix} q_1 \\ q_2 \\ q_3 \\ q_4 \end{pmatrix}^{-1} = \begin{pmatrix} -q_1 \\ -q_2 \\ -q_3 \\ q_4 \end{pmatrix}, \quad (8)$$

$$\left\{ \begin{array}{l} H(v) = -\sum_{j=1}^m (p_j \ln p_j), \\ \mu(v) = E(v_i) = \frac{1}{d} \sum_{i=1}^d v_i, \\ \sigma^2(v) = E[(v_i - \mu(v))^2] = \frac{1}{d} \sum_{i=1}^d [(v_i - \mu(v))^2], \end{array} \right. \quad (9)$$

其中: d 为检测窗口, 窗口 d 中 v 具有 m 个不同取值. 记 k 为窗口 d 中一数值 $v_j \in \{v\}$ 出现的次数, $p_i = \frac{k}{d}$ 表示为 v_j 出现的概率.

均值和标准差体现了残差的统计学特性, 信息熵体现了残差的变化剧烈程度, 综合均值、均方差和信息熵, 能更有效地检测出残差中所包含的故障信息.

3.3 基于SVM的故障检测

SVM是一种监督学习(supervised learning)的机器学习方法, 可以实现对数据的二元分类(binary classification), 其决策边界是对学习样本求解的最大边距超平面, 在解决小样本、非线性、高维度识别问题上有许多优势^[13-14].

SVM通过使用核函数(kernel function)将输入向量映射到特征空间, 并在特征空间中寻找一个最优分类超平面 H , 使得不同特征的样本分布在超平面两侧实现数据分类. 通过最大化不同样本特征到超平面之间的空白区域, SVM可以实现对线性可分数据的最优分类.

对于一个残差分量 r_i ($r_i \in r$)而言, 其具有3维的数据特征: 均值 μ 、标准差 σ^2 和信息熵 H , 则可构造SVM样本 $\Phi(r_i) = (\mu(r_i) \ \sigma^2(r_i) \ H(r_i))$.

由于SVM仅需辨识正常数据和故障数据, 所以仅要求故障样本能区分子正常样本, 而无需每一类故障的数据样本. 采集健康样本 Φ_h 和故障样本 Φ_f 对SVM进行训练, 使SVM能够辨识故障数据.

3.4 故障定位

用NN对式(4)进行建模, 其输入为姿态敏感器测量值. 由于动力学过程相对独立于运动学过程, 所以星敏感器故障时, ACS系统和NN的动力学部分输入相同, 残差 r_ω 应与无故障一致. 而动力学和运动学部分的输入都包含了角速度 ω , 陀螺仪故障和执行器故障都同样会导致角速度测量值 ω_s 异常, 从而使得 ω_s 和 q_s 检测异常, 而由于 ω_s 和 q_s 之间缺乏足够的冗余信息, 仅依靠这两者难以区分陀螺仪故障和执行器故障.

根据图2可知, 执行器故障时, T'_q 同时影响动力学

和运动学过程, 这个过程中, 角速度 ω 和姿态角 q 之间满足运动学约束关系, 即满足式(1). 而敏感器故障时, ω_s 和 q_s 之间不满足式(1)关系.

由于式(1)作为姿态运动的数学描述, 与实际对象的物理参数无关, 仅与对象的角速度和姿态有关. 所以可以结合运动学分析, 检测 ω_s 和 q_s 之间是否满足式(1)来区分执行器和敏感器故障.

利用 $q_s(t)$ 和 $\omega_s(t)$, 根据姿态运动学微分方程迭代对 $\hat{q}(t + T_c)$ 进行递推求解. 检测 \hat{q} 和 q_s 之间误差是否超过一定阈值, 当两者间误差超过阈值, 则认为运动学约束被破坏, 属于敏感器故障, 否则敏感器无故障. 记 $r_{\hat{q}} = \hat{q}^{-1} \otimes q_s$, 则结合运动学约束对不同故障进行定位, 其细节如表1所示.

表 1 故障定位表

Table 1 Fault isolation sheet

故障点	r_q 异常	r_ω 异常	$r_{\hat{q}}$ 异常
执行器	1	1	0
星敏感器	1	0	1
陀螺仪	1	1	1

执行器故障时, 检测结果应为 r_ω 和 r_q 检测出异常, 而 $r_{\hat{q}}$ 正常; 陀螺仪故障时, 检测结果应为 r_ω , r_q 和 $r_{\hat{q}}$ 均异常; 星敏感器故障时, 检测结果应为 $r_{\hat{q}}$ 和 r_q 检测出异常, 而 r_ω 正常.

4 仿真验证

搭建仿真对方法进行验证, 卫星执行器为“三正一斜”安装的飞轮, 敏感器为陀螺仪和星敏感器.

设置的故障类型如表2所示, 其中: $-1 < n_{i:j} < 1$ 表示 i 行 j 列的噪声; ω_w 为飞轮转速; f_1 中 $\eta < 1$, 仿真飞轮工作效率下降; f_2 , f_3 中 a 表示噪声的幅值, 仿真敏感器噪声故障.

表 2 故障仿真设置

Table 2 Faults simulation settings

故障点	故障类型	故障表现
执行器	f_1	$\omega'_w = \eta \cdot \omega_w$
星敏感器	f_2	$q'_s = q_s + a \cdot n_{4:1}$
陀螺仪	f_3	$\omega'_s = \omega_s + a \cdot n_{3:1}$

搭建NN为2个隐层, 每个隐层有120个节点, 收集近300个正常机动过程的ACS系统敏感器信号对NN进行训练. $t = 100$ 时注入机动指令, 将ACS系统敏感器信号与对应NN建模误差分别画图, 结果如图4所示.

图中左侧分别为姿态四元数和角速度的测量值, 右侧为对应的信号残差. 可以看到, 使用NN对ACS系统建模, 在机动初始阶段误差较大, 但与原信号相比小了至少2个数量级, 稳定段误差则更小, 说明NN建模精度满足故障诊断要求.

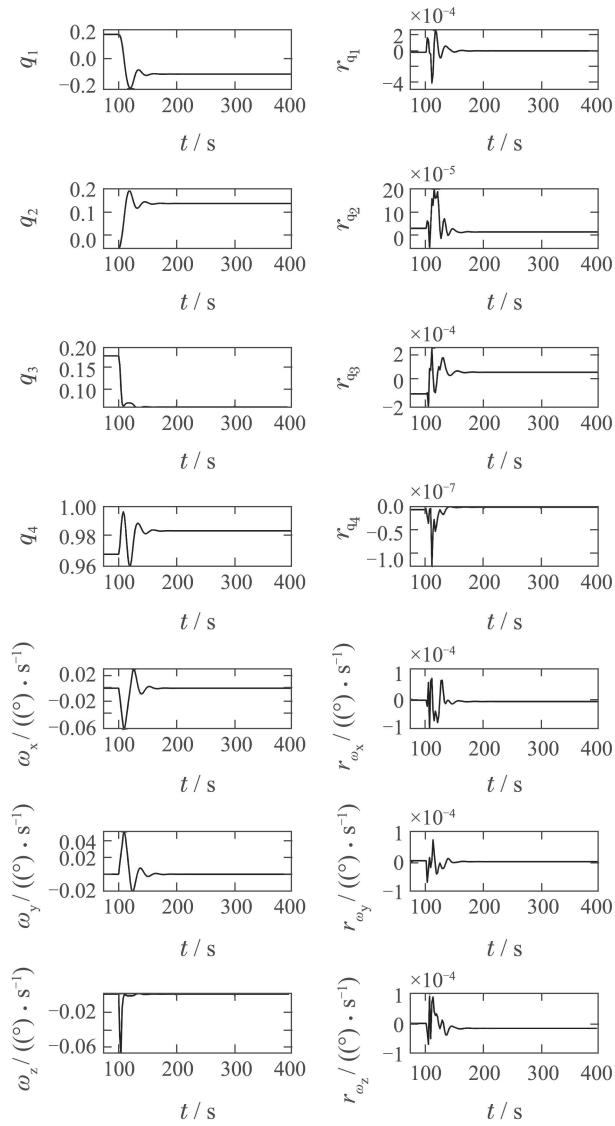


图 4 神经网络建模误差

Fig. 4 Error of NN modelling

设置执行器故障幅值 $\eta = 0.9$, 陀螺仪故障幅值 $a = 1 \times 10^{-2}(\text{°})/\text{s}$, 星敏感器故障幅值为 $a = 1 \times 10^{-3}$.

以 r_{q_1} 为例说明残差特征提取的有效性, 在一个机动过程中 $t \geq 200$ s 处注入故障, 实时计算残差, 并对

残差进行特征提取, 所得结果残差及其特征如图 5 所示。从图 5 中可以看到, 相较于故障发生前, 故障发生后 $\mu(r_{q_1})$, $\sigma^2(r_{q_1})$ 和 $H(r_{q_1})$ 有显著的变化。

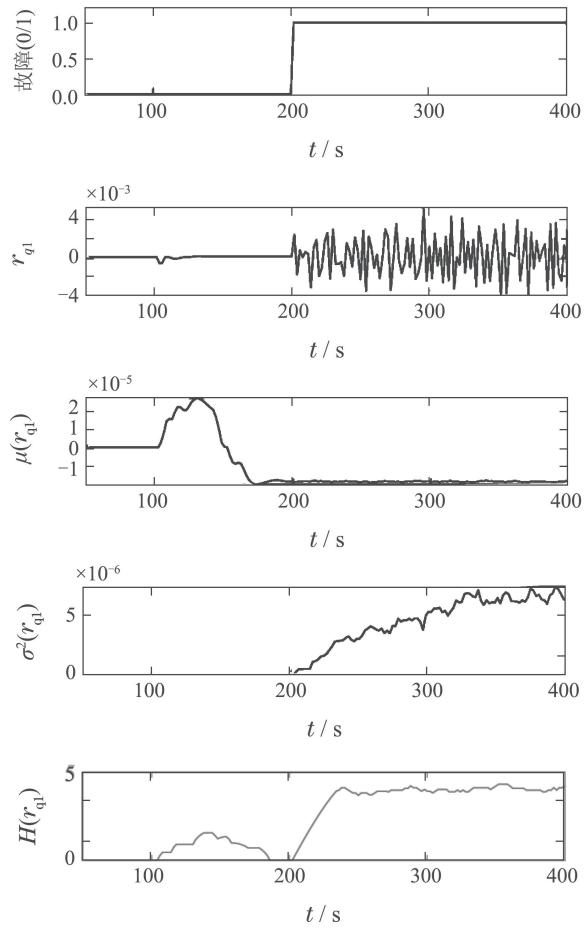
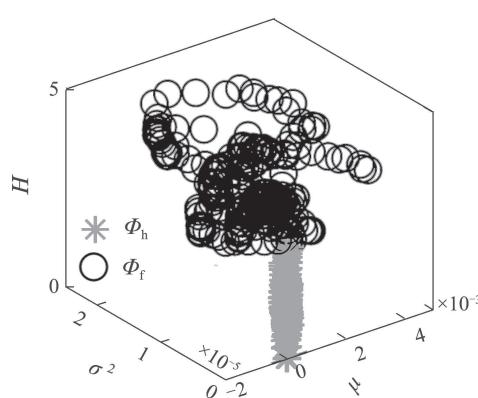


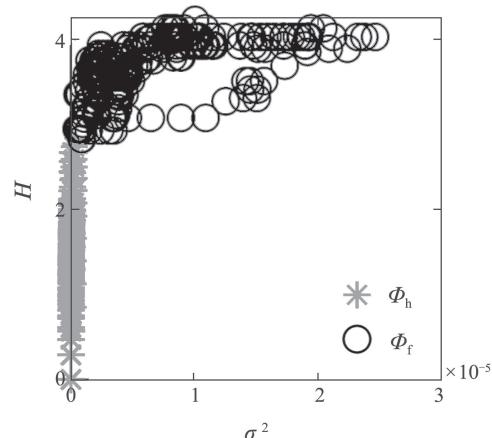
图 5 故障对残差及其特征的影响

Fig. 5 Fault's influence on residuals and their features

提取姿控系统执行器故障数据的残差特征 Φ_f , 以及无故障时的数据特征 Φ_h , 分别贴上标签 1 和 0, 对 SVM 进行训练。将 Φ_f 和 Φ_h 作三维散点图如图 6 所示, 可以看到 Φ_f 和 Φ_h 的分布空间和分布特点都有较大的区别。



(a) 故障分布



(b) 三视图 1

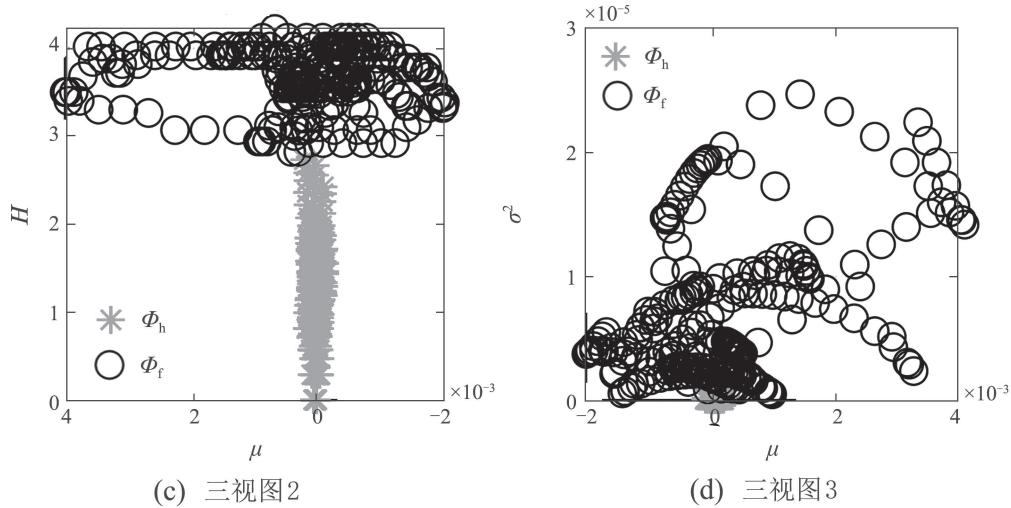


图 6 正常/故障特征点分布

Fig. 6 Distribution of healthy/faulty features

图6中: Φ_h 分布较为集中, Φ_f 分布较为散乱. 而从特征分布的三视图中无论哪个视图, Φ_f 和 Φ_h 之间都有交集, 由此可见特征点 $\Phi = (\mu \quad \sigma^2 \quad H)$ 中各个分量对残差的不同变化特性敏感程度不同, 结合各个分量进行故障检测具有必要性.

为了说明故障定位方法的有效性, 设置不同的故障, 检查 r_ω , r_q 和 r_q 对不同故障的响应. $100 \leq t \leq 102$ 时注入 f_1 故障, $t = 120$ 时注入 f_2 故障, $t = 140$ 时注入 f_3 故障, 得到结果如图7所示.

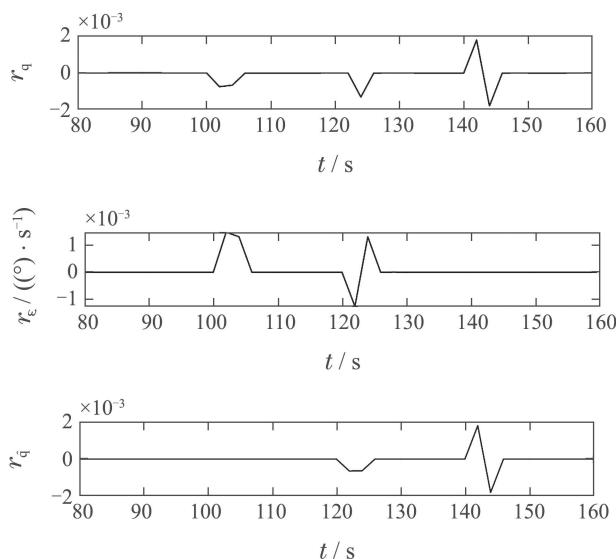


图 7 不同故障对系统的影响

Fig. 7 Influence of different faults on ACS

图7中: 执行器故障时, r_ω 和 r_q 均有变化, 而 $r_{\dot{q}}$ 却保持正常水平; 陀螺仪故障时, r_ω , r_q 和 $r_{\dot{q}}$ 均显示出波动; 星敏感器故障时, 由于动力学模块相对独立于运动学模块, r_ω 未显示波动, r_q 和 $r_{\dot{q}}$ 发生变化. 由图7可见, 本方法能有效分离执行器故障和敏感器故障.

记系统健康无故障的情况为 h_0 , 仿真每一类故障

的200次机动过程，在线进行故障检测定位，统计诊断结果得到表3。

表 3 故障检测定位结果

Table 3. Fault detection and location results

故障类型	检测成功率/%	定位结果/%					定位准确率/%
		f_1	f_2	f_3	h_0	其他	
h_0	—	0	0	0	97.63	2.37	97.63
f_1	97.89	97.89	0	0	0	2.11	97.00
f_2	100	0	100	0	0	0	100
f_3	100	0	0	100	0	0	100

从表3的统计结果来看,本方法对不同故障检测成功率和定位准确率均达到97%以上,说明本方法对姿控闭环系统执行机构故障和传感器故障具有良好的自主检测定位能力。

5 总结

本文通过分析姿控系统执行器和敏感器故障对系统的影响,设计了基于NN与SVM结合的方法故障检测定位方案,采用NN预测输出与姿控系统敏感器信号生成残差,对残差进行特征提取;采用SVM辨识残差特征检测故障,并结合运动学分析定位故障。从仿真结果可以看出,本文所提出的方法具备卫星执行器和敏感器的自主故障检测定位能力。

本文方法优点在于NN建模方法不依赖于卫星物理参数,最大化了方法的可移植性;用SVM进行故障检测,所需故障样本量少且无需每类故障的数据样本;对残差进行了充分的特征提取,综合多种手段捕捉故障信息,提高了故障检测的准确率;结合运动学特性实现了故障定位.本文方法设计简单、有效,为工程系统提供了应用参考.

参考文献:

- [1] WANG Dayi, MENG Linzhi, YE Peijian, et al. Research of autonomous operation technology for deep space probe. *Spacecraft Engineering*, 2018, 27(6): 5 – 14.
(王大铁, 孟林智, 叶培建, 等. 深空探测器的自主运行技术研究. 航天器工程, 2018, 27(6): 5 – 14.)
- [2] LI Hongjue, DONG Yunfeng. Intelligent development technology of satellite fault diagnosis system. *Aerospace Shanghai*, 2017, 34(3): 52 – 59.
(李洪珏, 董云峰. 卫星故障诊断系统智能研制技术研究. 上海航天, 2017, 34(3): 52 – 59.)
- [3] ZHANG Sen, SHI Jun, WANG Jiulong. Satellite on-board failure statistics and analysis. *Spacecraft Engineering*, 2010, 19(4): 41 – 46.
(张森, 石军, 王九龙. 卫星在轨失效统计分析. 航天器工程, 2010, 19(4): 41 – 46.)
- [4] ZHANG Hua, SHEN Rongkang, ZONG Yiyuan, et al. On-orbit fault statistical analysis for remote sensing satellite. *Spacecraft Environment Engineering*, 2015, 32(3): 324 – 329.
(张华, 沈嵘康, 宗益燕, 等. 遥感卫星在轨故障统计与分析. 航天器环境工程, 2015, 32(3): 324 – 329.)
- [5] ZHOU Donghua, LIU Yang, HE Xiao. Review on fault diagnosis techniques for closed-loop systems. *Acta Automatica Sinica*, 2013, 39(11): 1933 – 1943.
(周东华, 刘洋, 何潇. 闭环系统故障诊断技术综述. 自动化学报, 2013, 39(11): 1933 – 1943.)
- [6] DU Y, BUDMAN H, DUEVER T A. Integration of fault diagnosis and control based on a trade-off between fault detectability and closed loop performance. *Journal of Process Control*, 2016, 38: 42 – 53.
- [7] CHENG Y, JIANG B, LU N, et al. Incremental locally linear embedding-based fault detection for satellite attitude control systems. *Journal of the Franklin Institute*, 2016, 353(1): 17 – 36.
- [8] ZHAO S L, ZHANG Y C. SVM classifier based fault diagnosis of the satellite attitude control system. *2008 International Conference on Intelligent Computation Technology and Automation (ICICTA)*. Changsha, Hunan: IEEE Computer Society, 2008.
- [9] SHENG G, WEI Z, XU H, et al. Neural network-based fault diagnosis scheme for satellite attitude control system. *2018 Chinese Control and Decision Conference (CCDC)*. Shenyang: IEEE, 2018.
- [10] BALDI P, CASTALDI P, MIMMO N, et al. Combined singular perturbations and nonlinear geometric approach to FDI in satellite actuators and sensors. *IFAC—PapersOnLine*, 2017, 50(1): 7253 – 7259.
- [11] JIANG Linfeng. The circuit of fault diagnosis by neural network. *Applications of IC*, 2018, 35(12): 21 – 22.
(蒋霖锋. 基于神经网络的电路故障诊断. 集成电路应用, 2018, 35(12): 21 – 22.)
- [12] ADOUNI A, CHARIAG D, DIALLO D, et al. FDI based on artificial neural network for low-voltage-ride-through in DFIG-based wind turbine. *ISA Transactions*, 2016, 64: 353 – 364.
- [13] JAN S U, KOO I S. Sensor faults detection and classification using SVM with diverse features. *2017 International Conference on Information and Communication Technology Convergence (ICTC)*. Jeju Island, Korea: IEEE, 2017: 576 – 578.
- [14] JING C, HOU J. SVM and PCA based fault classification approaches for complicated industrial process. *Neurocomputing*, 2015, 167: 636 – 642.

作者简介:

- 叶正宇 硕士研究生, 研究方向为航天器姿态控制系统故障诊断,
E-mail: kasoll076@outlook.com;
- 程月华 副教授, 博士, 研究方向为航天器故障诊断与健康管理,
E-mail: chengyuehua@nuaa.edu.cn;
- 韩笑冬 研究员, 博士, 研究方向为航天器总体设计和故障诊断,
E-mail: 13426461933@163.com;
- 姜斌 教授, 博士, 研究方向为故障诊断技术, E-mail: binjiang
@nuaa.edu.cn.