

doi: 10.7690/bgzdh.2020.07.001

基于 1D-CNN 的卫星姿态控制系统故障诊断方法

闻新¹, 龙弟之¹, 王俊鸿¹, 魏炳翌²

(1. 南京航空航天大学航天学院, 南京 210016; 2. 中国运载火箭技术研究院北京航天自动控制研究所, 北京 100854)

摘要: 为解决卫星姿态控制系统中自主故障检测和诊断的问题, 提出一种改进的 1D-CNN 卫星姿态控制系统故障诊断方法。以卫星姿态控制系统的故障诊断为背景, 构建航天器姿态动力学模型, 将卷积神经网络(convolutional neural network, CNN)与快速卷积算法相结合, 对卷积神经网络的拓扑结构进行改进, 根据 BP 算法, 将 1 维原始数据作为输入, 结合反作用飞轮作为执行机构的技术特征, 给出一种基于卷积神经网络的故障检测和隔离方法。仿真结果验证了该方法对卫星姿态控制系统实时故障检测和分类的有效性。

关键词: 故障诊断; 卷积神经网络; 航天器姿态控制系统; 反作用飞轮

中图分类号: TP277 **文献标志码:** A

Fault Diagnosis Method of Satellite Attitude Control System Based on 1D-CNN

Wen Xin¹, Long Dizhi¹, Wang Junhong¹, Wei Bingyi²

(1. Academy of Astronautics, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;

2. Beijing Aerospace Automatic Control Institute, China Academy of Launch Vehicle Technology, Beijing 100854, China)

Abstract: To solve the problem of autonomous fault detection and diagnosis in satellite attitude control system, an improved one-dimensional convolution neural network fault diagnosis method is proposed. Based on the fault diagnosis of satellite attitude control system, the attitude dynamics model of spacecraft is constructed. The convolutional neural network (CNN) is integrated with fast convolution algorithm, and the topology of convolutional neural network is improved. According to BP algorithm, a fault detection and isolation method based on convolution neural network is proposed, which takes one-dimensional raw data as input and combines the technical characteristics of reaction flywheel as actuator. The simulation results verify the validity of this method for real-time fault detection and classification of satellite attitude control system.

Keywords: fault diagnosis; convolutional neural network; spacecraft attitude control system; reaction flywheel

0 引言

据统计, 1980—2005 年, 全世界近 130 个航天器发生了 156 次在轨故障, 造成了重大的经济损失^[1]。近十几年来, 我国发射的卫星越来越多, 出现了很多故障, 针对航天器的故障诊断技术已经引起航天领域专家学者的重点关注。

在过去 20 年里, 针对卫星这类复杂系统的故障诊断问题, 许多专家和学者投入大量的精力^[2]。文献[3]利用单隐层前馈小波神经网络设计自适应观测器估计系统状态值, 利用残差进行故障检测。文献[4]采用神经网络与支持向量机技术相结合的方法对非线性系统进行故障检测与诊断, 通过神经网络判断系统故障, 运用多个支持向量机对故障类型进行确定。文献[5]设计了一种针对复杂非线性系统的故障诊断系统, 利用广义回归神经网络的并行结构与自学习能力快速确定故障类型。文献[6]针对现有的故障诊断技术难以处理建模不确定性、非线性

的系统, 将神经网络与模糊算法相结合, 进行系统建模与辨识。文献[7-8]利用故障参数概念进行故障参数建模, 使用神经网络故障参数估计器结合数学模型进行单个故障检测。在此基础上, 文献[9]提出了一种新型并联结构故障参数诊断方法, 从而解决多故障参数的检测和隔离问题。

随着人工智能技术的快速发展, 深度学习已成为故障诊断的有效方法。深度学习可以自动学习原始数据的抽象表示功能^[10-11], 有效避免了人工对数据特征的识别。几种深度学习方法已经应用于故障诊断, 如深度置信网络(deep belief networks, DBN)^[12]、堆叠去噪自动编码器^[13-14]以及卷积神经网络^[15]。上述方法虽然取得了良好的效果, 但是存在网络结构复杂以及计算量庞大的问题。

针对卫星姿态控制系统故障诊断高效性与实时性的要求, 笔者将 1 维卷积神经网络与快速卷积算法相结合, 搭建自适应 1 维快速卷积神经网络, 设

收稿日期: 2020-02-19; 修回日期: 2020-03-27

作者简介: 闻新(1961—), 男, 辽宁人, 博士, 教授, 从事航天器编队控制、航天器故障诊断研究。E-mail: Wen-xin2004@126.com。

计一种集故障检测与故障分类为一体的故障诊断方法。

1 姿态动力学模型

航天器姿态动力学模型如下：

$$I_{sat} \dot{\omega} + \omega \times (I_{sat} \omega + I_{ro} \omega_{ro}) + \tau_{ro} = \tau_{dist} \quad (1)$$

式中： I_{sat} 、 I_{ro} 分别为卫星和反作用飞轮的转动惯量； $\omega = [\omega^x \ \omega^y \ \omega^z]^T$ 为卫星三轴角速度矢量； ω_{ro} 为反作用飞轮的角速度； τ_{ro} 、 τ_{dist} 分别为反作用飞轮和外部干扰力矩。

反作用飞轮主要由电动势转矩限制回路、轴承摩擦力与扰动、速度限制器 3 大非线性部分组成。设反作用飞轮的电机电流 I_m 和角速度 ω 为飞轮的状态量，控制器输出的电压信号 V_{Com} 为输入，反作用飞轮产生的转矩 τ_{ro} 作为输出，反作用飞轮模型的状态方程为：

$$\left. \begin{aligned} \dot{I}_m &= G_d \omega_d (f_3(\omega, I_m) - f_5(\omega)) - \omega_d I_m + G_d \omega_d V_{Com} \\ \dot{\omega} &= \frac{1}{J_\omega} [f_1(\omega) + k_t I_m (f_2(\omega) + 1) - \tau_v \omega - \tau_c f_4(\omega) + \tau_{noise}] \\ \tau_{ro} &= f_1(\omega) + k_t I_m (f_2(\omega) + 1) - \tau_v \omega - \tau_c f_4(\omega) + \tau_{noise} \end{aligned} \right\} \quad (2)$$

式中： f_1, f_2 为电机存在的干扰； f_3 为 EMF 转矩限制回路； f_4 为库仑摩擦中不连续的符号函数； f_5 为速

度限制器回路。分别表示如下：

$$\left. \begin{aligned} f_1(\omega) &= C \sin \frac{Nt}{2} \omega \\ f_2(\omega) &= B \sin 3Nt\omega \\ f_3(\omega, I_m) &= \frac{\exp(-aV(\omega, I_m, V_{bus}))}{1 + \exp(-aV(\omega, I_m, V_{bus}))} V(\omega, I_m, V_{bus}) \\ f_4(\omega) &= \frac{1 - \exp(-a\omega)}{1 + \exp(-a\omega)} \\ f_5(\omega) &= \frac{1}{2} \left(\frac{k_s(\omega - \omega_s f_4(\omega))}{1 + \exp(-a(\omega - \omega_s))} + \frac{k_s(\omega - \omega_s f_4(\omega))}{1 + \exp(a(\omega + \omega_s))} \right) \\ V(\omega, I_m, V_{bus}) &= k_f [V_{bus} - 6 - \frac{1 + R_{in} I_{bus}}{1 + \exp(-aI_{bus})} - \frac{1 - \exp(-ak_e \omega)}{1 + \exp(-ak_e \omega)} k_e \omega] \end{aligned} \right\} \quad (3)$$

式中： G_d, ω_d 分别为飞轮驱动增益和频率； J_ω 为飞轮转动惯量； k_t 为电机扭矩参数（电机力矩和电机电流的比值）； τ_v, τ_c 分别为粘滞力矩和库仑摩擦系数； τ_{noise} 为低频率噪声扰动力矩； B, C 为电机力矩震荡系数； N 为电机磁极数； I_{bus}, V_{bus} 分别为母线电流和电压； ω_s 为限制转速； k_s 为超速循环增益； k_f, k_e 分别为电压反馈增益和电动势反馈常数； R_{in} 为输入阻抗。搭建三轴稳定航天器姿态控制系统如图 1 所示。




图 1 航天器 3 轴稳定姿态控制系统

2 飞轮故障分析与数据预处理

2.1 故障分析

反作用飞轮主要故障源包括温度失衡和电机电流不稳定造成的故障。

2.1.1 温度过热故障

粘性摩擦是反作用飞轮主要的轴承摩擦方式，与温度密切相关。在反作用飞轮模型中，粘滞力矩 τ_v 可以表示为

$$\tau_v = (0.0049 - 0.00002(T + 30))\omega \quad (4)$$

在太空环境中，卫星内部不断产生热量，同时还会吸收外部热量，如果飞轮组件不能及时散热，会导致温度不断升高，这时粘性摩擦系数将会发生改变，引发卫星姿态控制系统故障。假设仿真时间 80 s 时，发生温度 T 不断累积升高的故障，则数学

描述：

$$T(t) = \begin{cases} T^{norm} & t < 80 \\ T^{norm} + \log_{\lambda_T}^{(t-79)} & 80 \leq t \end{cases} \quad (5)$$

式中： T^{norm} 为反作用飞轮正常工作情况下的温度； λ_T 为温度故障系数。

2.1.2 电机电流故障

输出力矩与电机电流有直接的关系。在反作用飞轮模型中，可以用电机扭矩参数 k_t 来间接反映电机电流的变化。通过定义可得

$$k_t = \tau_m / I_m \quad (6)$$

当元器件老化导致电机电流变化超出可控范围时，电机输出力矩也会达不到期望值，引发卫星姿态控制系统故障。为了更真实地表示故障情况，在电机电流中引入正弦时变故障，电机转矩增益系数


$$k_t(t) = \begin{cases} k_t^{\text{nom}} & t < 80 \\ k_t^{\text{nom}} - \lambda_l \sin(2\pi t/1000) & 80 \leq t \end{cases} \quad (7)$$

式中： k_t^{nom} 是航天器姿态控制系统中反作用飞轮正常工作情况下电机转矩增益系数； λ_l 为电流故障系数。


2.2 数据预处理

对姿态控制系统模型进行数值仿真获得所需要的训练和测试数据。首先，设定卫星三轴转动惯量 $I_x=450 \text{ kg/m}^2$, $I_y=200 \text{ kg/m}^2$, $I_z=440 \text{ kg/m}^2$, 初始时刻三轴姿态角都为 10° , 初始角速度都为零, 设计控制器实现卫星三轴稳定。不考虑冗余轮的故障情况, 在航天器俯仰轴上安装的反作用飞轮中引入温度故障与电流故障 2 种间歇时变故障。对不同故障情况下的输出力矩进行采样, 得到健康情况、电流故障和电压故障各 300 例数据。


进行训练之前, 需要对数据进行预处理。首先将原始信号降采样, 然后通过 2 阶陷波滤波器对当前数据进行滤波, 最后对预处理信号进行归一化处理, 作为 1 维卷积网络的输入。图 2 显示了预处理后, 健康和 2 类故障情况下电机输出力矩信号。



(a) 系统健康



(b) 温度故障



(c) 电流故障

图 2 预处理后系统电机输出的力矩信号

3 故障诊断方法

针对卷积神经网络复杂结构导致的特征提取、分类过程需要花费较多时间和计算空间的问题, 笔者提出网络结构相对简单的 1 维卷积神经网络, 并结合快速卷积算法来提高故障诊断效率, 从而更好地应用于卫星。

3.1 自适应 1 维卷积神经网络

对卷积神经网络的拓扑结构进行改进, 使用自适应 1 维神经网络来实现卫星姿态控制系统飞轮执行机构故障检测与分类。改进后的自适应神经网络拓扑结构对输入信号大小没有限制。如图 3 所示, 1 维卷积层结构由输入层、卷积层、MLP (multi-layer perceptron) 层和输出层组成。




图 3 1 维卷积层结构

1 维卷积神经网络卷积核大小和池化层的参数分别由标量 kn 合 ss 表示。如图 3 所示, 在 1 维卷积神经网络中, 从卷积层 $l-1$ 到当前卷积层 l 中节点 k 的输入可以表示为

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} \text{conv1D}(w_{ik}^{l-1}, s_i^{l-1}) \quad (8)$$

式中： x_k^l , b_k^l 分别为卷积层 l 节点 k 的输入和偏置； s_i^{l-1} 为卷积层 $l-1$ 节点 i 的输出； w_{ik}^{l-1} 为节点 i 到节点 k 对应的卷积核。用 f 表示激活函数：

$$y_k^l = f(x_k^l), \quad s_k^l = y_k^l \kappa(ss) \quad (9)$$

式中： y_k^l 为卷积层输入到池化层的中间值； s_k^l 为池化处理后的输出； $\kappa(ss)$ 为以参数 ss 对特征信息进行池化。

自适应 1 维神经网络结构可以自动给出最后一个卷积层的池化因子。它被设定为其输入数组的大小。例如在图 3 中, 假设卷积层 $l+1$ 是最后一个卷积层, 因为输入数组大小为 8, 则系统自动将 ss 赋值为 8。这种自适应能力使得不管输入大小如何, 最后一个卷积层通过池化作用都可以输出一个标量值。

3.2 快速算法

已知一个拥有 K 个大小为 $R \times S$ 卷积核的卷积层, 其通道为 C , 处理 N 幅大小为 $H \times W$ 的图像, $G_{k,u,v}$ 为卷积核 k 中第 u 行第 v 列元素, $D_{i,x,y}$ 为图像 i 中第 x 行第 y 列元素。通过卷积运算, 输出结果 $Y_{i,k,x,y}$ 可以表示为

$$Y_{i,k,x,y} = \sum_{c=1}^C \sum_{v=1}^S \sum_{u=1}^R D_{i,c,x+u,y+v} G_{k,c,u,v} \quad (10)$$

对于 1 维卷积 $F(m,r)$, m 为输出数组维度, r 为卷积核大小。根据上式, 卷积算法需要 $m \times r$ 次乘法。将其转化为如下形式:

$$F(m,r) = A^T[(Gg) \odot (B^T d)] \quad (11)$$

式中: \odot 为元素对应相乘; $g=[g_1 \cdots g_r]^T$ 为 1 维卷积核; $d=[d_1 \cdots d_{m+r-1}]^T$ 为 1 维输入; A, G, B 分别为反向转换矩阵、卷积核转换矩阵和数据转换矩阵。以 $m=4, r=3$ 为例, 只需进行 $m+r-1$ 次乘法, 即 6 次, 而传统卷积算法则需 12 次。在卷积核转换, 数据转换和反向转换环节各需进行 [6 6 4] 次加法, 通过适当增加简易的加法运算, 有效降低了运算复杂度, 提升了运算速度。

进一步, 令 $U=Gg$, $V=B^T d$, 结合式(11), 第 i 个输入通过第 k 个卷积核的输出可以写为

$$Y_{i,k} = F(m,r) = A^T \sum_{c=1}^C [U_{k,c} \odot V_{c,i}] \quad (12)$$

$$\text{令 } M_{k,i} = \sum_{c=1}^C U_{k,c} \odot V_{c,i}, \text{ 有}$$

$$M_{k,i}^\xi = \sum_{c=1}^C U_{k,c}^\xi V_{c,i}^\xi \quad (13)$$

式中: $M_{k,i}^\xi$ 为 $M_{k,i}$ 的第 ξ 个元素; $U_{k,c}^\xi$ 为 $U_{k,c}$ 的第 ξ 个元素; $V_{c,i}^\xi$ 为 $V_{c,i}$ 的第 ξ 个元素。由于式(13)是矩阵乘法, 可以写为

$$M^\xi = U^\xi V^\xi \quad (14)$$

至此, 1 维快速卷积算法为:

for $k=0:K$ do

for $c=0:C$ do

$$u = Gg_{k,c}, \text{ 其中 } U_{k,c}^\xi = u_\xi$$

for $b=0:P$ do

for $c=0:C$ do

$$v = B^T d_{c,b}, \text{ 其中 } V_{c,b}^\xi = v_\xi$$

for $\zeta=0:a$ do

$$M^\zeta = U^\zeta V^\zeta$$

for $k=0:K$ do

for $b=0:P$ do

$$m_\xi = M_{k,b}^\xi$$

$$Y_{k,b} = A^T m$$

3.3 权值更新

设 $l=1$ 和 $l=L$ 分别为输入层和输出层, N_L 为训练数据中状态分类总数。对于输入 p 及其对应目标输出 t_i^p 和实际输出 $[y_1^l, \dots, y_{N_L}^l]$, 选取交叉熵误差 (cross entropy error, CEE) E_p 作为输入 p 的损失函数:

$$E_p = \text{CEE}(t_i^p, [y_1^l, \dots, y_{N_L}^l]) = - \sum_{i=1}^{N_L} t_i^p \lg y_i^l \quad (15)$$

利用 BP 算法, 增量 Δ_i^{l+1} 从隐藏 MLP 层到最后 一个卷积层的增量 Δs_k^l 可以表示为:

$$\partial E / \partial s_k^l = \Delta s_k^l = \sum_{i=1}^{N_{l+1}} \Delta_i^{l+1} w_{ki}^l \quad (16)$$

进一步将其反向传播为输入增量 Δ_k^l 。将零阶上采样映射记为 $us_k^l = up(s_k^l)$, 可以得到

$$\Delta_k^l = \frac{\partial E}{\partial us_k^l} \frac{\partial us_k^l}{\partial y_k^l} f'(x_k^l) = up(\Delta s_k^l) \beta f'(x_k^l) \quad (17)$$

由于 s_k^l 中的每个元素都是通过平均池化得到, 所以 $\beta = (ss)^{-1}$ 。前向传播时, 第 l 层的节点 k 以权值 w_{ki}^l 与下一层的节点 i 相连, 那么节点 i 的增量 Δ_i^{l+1} 将以相同的权值反向传播至上一层节点, 求和得到该节点的增量, 即

$$\partial E / \partial s_k^l = \Delta s_k^l = \sum_{i=1}^{N_{l+1}} \Delta_i^{l+1} (\partial x_i^{l+1} / \partial s_k^l), \quad (18)$$

式中 $x_i^{l+1} = \dots + s_k^l * w_{ki}^l + \dots$, 符号 * 表示采用零填充的 1 维卷积运算。为了简化问题, 单个分析输出 $s_k^l[m]$ 与下一层输入 $x_i^{l+1}[m]$ 的关系, 假设一个大小为 3 的卷积核:

$$\left. \begin{aligned} x_i^{l+1}[m-1] &= \dots + s_k^l[m] \bullet w_{ki}^l[2] + \dots \\ x_i^{l+1}[m] &= \dots + s_k^l[m] \bullet w_{ki}^l[1] + \dots \\ x_i^{l+1}[m+1] &= \dots + s_k^l[m] \bullet w_{ki}^l[0] + \dots \end{aligned} \right\} \quad (19)$$

因此, $s_k^l[m]$ 的增量可以表示如下:

$$\Delta s_k^l[m] = \sum_{i=1}^{N_{l+1}} \sum_{r=1}^1 \Delta_i^{l+1}[m+r] \bullet w_{ki}^l[1-r] \quad (20)$$

对于增量 Δs_k^l 则可以表示为:

$$\Delta s_k^l = \sum_{i=1}^{N_{l+1}} \text{conv1Dz}(\Delta_i^{l+1}, \text{rev}(w_{ki}^l)) \quad (21)$$

式中： $\text{rev}(\bullet)$ 表示 1 维数组的逆序； $\text{conv1Dz}(\bullet, \bullet)$ 表示零填充的 1 维快速卷积算法。

对于卷积核和偏置的更新，根据 BP 算法，将当前层的输出 s_k^l 和 $l+1$ 层节点 i 的增量 Δ_i^{l+1} 用于更新该节点的 1 维卷积核以及相连下一层的偏置。最终，损失函数对权值和偏置的导数可以表示为：

$$\left. \begin{aligned} \frac{\partial E}{\partial w_{ki}^l} &= \text{conv1D}(s_k^l, \Delta_i^{l+1}) \\ \frac{\partial E}{\partial b_i^{l+1}} &= \sum_n \Delta_i^{l+1}(n) \end{aligned} \right\} \quad (22)$$

4 仿真分析

为了评估笔者提出的卫星姿态控制系统故障诊断方法的有效性，采用文献[16]中提出的 4 个指标：检测准确度 Acc、敏感度 Sen、特异性 Spe 和阳性预测性 Ppr 来综合评估故障诊断方法的效果。首先对 1 维卷积神经网络输出的结果进行划分：将输出正确分类为温度故障 t_{F1} ，电流故障 t_{F2} 或是健康 t_H ；将温度故障错误分类为电流故障 f_{F12} 或健康 f_{H1} ；将电流故障错误分类为温度故障 f_{F21} 或健康 f_{H2} ；将系统健康错误分类为温度故障 f_{F1} 或电流故障 f_{F2} 。性能指标计算表达式如下：

$$\left. \begin{aligned} \text{Acc} &= \frac{t_{F1} + t_{F2} + t_H}{\Sigma} \\ \text{Sen1} &= \frac{t_{F1}}{t_{F1} + f_{F12} + f_{H1}}, \quad \text{Sen2} = \frac{t_{F2}}{t_{F2} + f_{F21} + f_{H2}} \\ \text{Spe} &= t_H / (t_H + f_{F1} + f_{F2}) \\ \text{Ppr} &= \frac{t_{F1} + t_{F2}}{t_{F1} + t_{F2} + f_{H1} + t_{F2} + t_{F21} + f_{H2}} \end{aligned} \right\} \quad (23)$$

式中 Σ 表示事件总和。

4.1 实验设置

预处理后，飞轮输出力矩信号为 240 个时域样本。采用的自适应 1 维卷积网络结构包含 3 个卷积层和 2 个 MLP 层。其中卷积层分别有 [60 40 40] 个节点，隐藏 MLP 层有 10 个节点，输出 MLP 层有 3 个节点，即故障分类数。1 维卷积神经网络的卷积

核和池化因子分别设置为 9 和 4，最后一个卷积层的池化因子自动设置为 4。

训练中，设置 2 个终止准则：迭代达到 1 000 次；最小训练分类误差小于 0.5%。设置学习率为 0.01，在每次迭代中应用基于 SGD 学习率自适应更新算法^[17]，以周期性下降的方式适当地减小学习率，从而更好地寻找全局最优解。

4.2 性能评估

将 900 组数据分为 660 组训练数据和 240 组测试数据，使用 Matlab 实现自适应 1 维快速卷积神经网络。对测试数据中 80 个健康、80 个温度故障和 80 个电流故障进行故障诊断实验。为了提高评估的有效性，进行 10 次实验。表 1 中给出了 10 次实验卫星姿态控制系统不同类型故障检测和分类的统计结果。

表 1 10 次实验故障分类结果

Actual result	Classification result		
	H	F_1	F_2
H	782	11	7
F_1	12	796	14
F_2	8	13	779

为了能够对笔者提出的故障诊断方法性能优劣有更直观的了解，将其与小波包分解和 FFT 特征提取技术，并结合 MLP、RBFN 神经网络进行比较分析。设置 MLP 和 RBNF 网络结构分别为 [32 64 32 3]，[32 32 32 3]，利用相同数据对 4 种故障分类网络 (WP-MLP、WP-RBFN、FFT-MLP、FFT-RBFN) 进行训练和测试，通过式(23)计算对应的性能指标，结果如图 4 和表 2 所示。




图 4 5 种故障诊断算法对应故障分类准确率

表 2 5 种故障诊断算法性能对比

Method	Fault diagnosis				
	Acc	Sen1	Sen2	Spe	Ppr
Proposed	97.375	97.000	97.375	97.750	97.188
WP-MLP	95.917	96.500	95.875	95.375	96.187
WP-RBFN	97.125	96.875	97.500	97.000	97.188
FFT-MLP	93.583	93.750	93.625	93.375	93.687
FFT-RBFN	93.625	93.125	94.000	93.750	93.563

实验采用 I5-7400、3.0 GHz 和 16 GB 内存计算

机对网络进行训练和测试，完成训练后的 5 种算法

对于测试数据特征提取和分类的平均时间分别如图 5 所示。




图 5 5 种故障诊断算法特征提取和分类平均时间

从以上的结果可以看出：相比目前常用的几类算法，自适应 1 维快速卷积神经网络故障诊断方法在诊断精度和诊断速度方面都有出色的性能，可以有效地用于卫星姿态执行机构的实时故障诊断。

5 结论

笔者提出一种基于卷积神经网络的航天器姿态控制系统故障诊断技术，使用卷积神经网络实现了故障检测和与分类的功能。通过自适应调整卷积输出层的池化因子，避免了手动调整网络结构参数与输入大小的约束问题。在完成故障检测和分类后，还需要对故障严重程度进行估计，方便容错控制的设计；将航天器集群与容错理论相结合，应用于卫星集群故障的实时监测将是今后的研究方向。

参考文献：

- [1] TFAZOLI M. A study of on-orbit spacecraft failures[J]. *Acta Astronautica*, 2009, 64(2): 195-205.
- [2] SULLIVAN J, GRIMBERG S, AMICO D. Comprehensive Survey and Assessment of Spacecraft Relative Motion Dynamics Models[M]. *Journal of Guidance, Control, and Dynamics*, 2017: 1-23.
- [3] WEN X, WANG J Y, XIN L. A Feed-Forward Wavelet Neural Network Adaptive Observer-Based Fault Detection Technique for Spacecraft Attitude Control Systems[J]. *Chinese Journal of Electronics*, 2018, 27(1): 102-108.
- [4] NIETO J P, LUIS G C, RABHI A, et al. Vehicle Fault Detection and Diagnosis combining AANN and ANFIS[J]. *IFAC Proceedings Volumes*, 2009, 42(8): 1079-1084.
- [5] CHIANG Y C, JUANG J C, YOUSSEF H. Neural

network approach to aircraft fault detection, isolation and estimation design[C]. *Aerospace Sciences Meeting & Exhibit*, 2013.

- [6] BARUA A, KHORASANI K. Hierarchical Fault Diagnosis and Fuzzy Rule-Based Reasoning for Satellites Formation Flight[J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2011, 47(4): 2435-2456.
- [7] BARUA A, KHORASANI K. Hierarchical Fault Diagnosis and Fuzzy Rule-Based Reasoning for Satellites Formation Flight[J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2011, 47(4): 2435-2456.
- [8] MRUGALSKI M. An unscented Kalman filter in designing dynamic GMDH neural networks for robust fault detection[J]. *International Journal of Applied Mathematics & Computer Science*, 2013, 23(1): 157-169.
- [9] SOBHANI-TEHRANI E, TALEBI H A, KHORASANI K. Hybrid fault diagnosis of nonlinear systems using neural parameter estimators[J]. *Neural Networks*, 2014, 50: 12-32.
- [10] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436.
- [12] SHAO H, JIANG H, ZHANG X, et al. Rolling bearing fault diagnosis using an optimization deep belief network[J]. *Measurement Science and Technology*, 2015, 26(11): 115002.
- [13] LU C, WANG Z Y, QIN W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. *Signal Processing*, 2016, 130(C): 377-388.
- [14] SHAO H, JIANG H, WANG F, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis[J]. *Knowledge-Based Systems*, 2017, 119: 200-220.
- [15] WEN L, LI X, GAO L, et al. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [16] HU Y H, PALREDDY S, TOMPKINS W J. A patient-adaptable ECG beat classifier using a mixture of experts approach[J]. *IEEE Transactions on Biomedical Engineering*, 1997, 44(9): 891-900.
- [17] KESKAR N S, SAON G. A nonmonotone learning rate strategy for SGD training of deep neural networks[C]. *ICASSP 2015 - 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2015.