

BP 神经网络用于火箭增压输送系统故障检测

张伟星, 李建民, 侯文, 王高, 罗悦, 薛震宇

(中北大学信息与通信工程学院, 山西 太原 030051)

摘要: 增压输送系统是火箭产生推力的核心系统, 其工作可靠性直接关系到运载火箭安全性。以某型号运载火箭第三级作为故障检测对象, 将遥测数据抽样和预处理, 降低数据规模和提高故障检测效率, 模拟常见故障和偶发故障扩大故障数据规模, 使得故障数据和正常数据均衡, 通过添加归一化时间序列区分火箭工况。经处理后的遥测数据用于训练 BP 神经网络, 故障检测结果表明: BP 神经网络可以利用火箭遥测数据对增压输送系统进行有效的故障检测, 正常数据误报率和故障数据漏报率均较低, 且可以满足实时故障检测需求。

关键词: 液体火箭; 遥测参数; BP 神经网络; 故障检测

中图分类号: V434, TP277 **文献标识码:** A **文章编号:** 1672-9374(2021)05-0085-07

BP neural network applied in fault detection of rocket pressurized delivery system

ZHANG Weixing, LI Jianmin, HOU Wen, WANG Gao, LUO Yue, XUE Zhenyu

(School of Information and Communication, North University of China, Taiyuan 030051, China)

Abstract: The pressurized delivery system is the core system of rocket to generate thrust, and its working reliability is directly related to the safety of launch vehicle. Taking the third stage of a certain type of launch vehicle as the fault detection object, the telemetry data is sampled and preprocessed to reduce the data scale and improve the fault detection efficiency. By simulating common faults and occasional faults to expand the fault data scale, the fault data and normal data are balanced, and the rocket working conditions are distinguished by adding normalized time series. The processed telemetry data is used to train BP neural network. The fault detection results show that BP neural network can effectively detect the fault of pressurized delivery system by using the rocket telemetry data, and the false alarm rate of normal data and false alarm rate of fault data are both low, and it can meet the real-time fault detection requirements.

Keywords: liquid rocket; telemetry parameter; BP neural network; fault detection

收稿日期: 2020-11-24; 修回日期: 2021-02-04

基金项目: 国家自然科学基金(61573323)

作者简介: 张伟星(1993—), 男, 硕士, 研究领域为数据挖掘及液体火箭故障检测。

通信作者: 李建民(1972—), 男, 博士, 副教授, 研究领域为舵机伺服技术、自动化测试与控制。

0 引言

据统计,到 20 世纪 70 年代美国所有液体火箭发射失败任务中,增压输送系统故障导致火箭发射失败的比例高达 28%,列火箭各系统故障比例之首^[1]。美国最早开始发展异常及故障检测系统、健康管理系 统对包括增压输送系统在内的各火箭系统的健康状况进行监测,取得了良好的效果^[2-5]。

传统的火箭故障检测方法有自适应方法(通过监测测量参数向量之间的相关关系的变化情况,来判断发动机是否发生故障^[6])、信号处理的方法(通过对火箭信号的预处理、特征提取、状态识别和诊断决策等环节,提出采用振幅和频率两参量包络曲线法诊断发动机故障的算法,并通过发动机热试车数据验证了该算法的有效性^[7])、数学模型的方法,建立故障仿真数学模型,选取特征参数,对于泄漏、堵塞及涡轮泵等典型故障模式可以进行有效识别和分离^[8])等。传统的火箭故障检测方法自学习能力弱,故障检测覆盖范围较低。随着数据科学的迅速发展,出现多种利用数据挖掘对液体火箭故障检测的方法,尤其是以深度学习为代表的智能故障检测方法利用火箭返回的大量数据,基于数据驱动建立可靠的故障检测模型^[9-10]。文献[11]评述了液体火箭发动机健康监控技术的两个主要方面,即故障检测和健康监测,并介绍了模型驱动、数据驱动和人工智能的液体火箭故障检测方法,对比了以上方法的适用范围和各自特点。

许多学者将关联规则、贝叶斯分类器、聚类算法、粒子群算法等数据挖掘方法应用于火箭的故障检测,取得了不错的效果^[12-15],以上算法具有一定的自学习能力并且对于偶发故障也有一定的检测能力。深度学习的发展也为火箭故障检测提供了更多的可能,文献[16]建立了液体火箭发动机参数选择层次结构模型,为科学合理地选择发动机地面试车实时故障检测参数提供了根据,解决了一直以来依靠定性方法确定发动机检测参数的问题。文献[17]采用 Hopfield 神经网络模拟发动机静态工作过程的非线性方程组并用 ART2 网络识别常见的几种故障模式。文献[18]应用动态神经网络在线辨识方法用于泵压式液体火箭发动机故障检测与分离。文献[19]将前向多层感知机神经网络应用

于液体火箭发动机故障检测和诊断。

以上液体火箭故障检测方法和健康监测系统存在的问题是:数据模型用到的训练集中实际发射和试车数据较少且数据规模较小,模型适用范围较小,无法从火箭系统层面对火箭健康状况进行全面监测,数据处理方法较为复杂无法满足实时检测需求等。本文在前人液体火箭故障检测方法和健康监测工作的基础上结合各种数据分析的优势提出针对液体火箭系统的故障检测方法。BP 神经网络可以进行离线训练,提前完成模型训练可以提高故障检测的效率。经过预处理的 18 个遥测参数属性可视为 181 矩阵,对 MATLAB 而言,处理如此大小的矩阵是非常迅速的,这样就能保证计算每个时刻点的试车或发射数据时系统的时耗尽可能少。每个数据集采样点之间的时间间隔为毫秒级能满足实时检测的需求。

1 数据预处理

本文数据来源于某型号运载火箭第三级试车和发射时,增压输送系统 17 个核心组件传感器返回数据,包括温度、压力、转速等物理量,增压输送系统绝大部分故障和异常可由这 17 个参数直接或间接反映,另外还增加归一化时间序列以区分减少火箭不同工况下参数变化带来的误判。该型号火箭在一百多秒的工作时间内产生上百万行数据,而且数据的量纲和数量级差异极大。为提高算法计算速度,实现实时故障检测的需求,必须对数据进行预处理,其处理过程分为数据抽样和数据归一化两个环节。

1.1 数据抽样

本文所研究的增压输送系统属于泵压式,构建 BP 神经网络故障检测参数属性如表 1 所示,数据已经过适当去密处理。

由表 1 可知故障检测参数采样频率为 25 ~ 375 Hz,整个试车和发射过程产生数万行数据,为降低数据规模,同时兼顾较早的捕获故障数据,本文设置数据抽样频率为 4 Hz,即每隔 0.25 s 抽取一个传感器返回数据作为研究数据。

增压输送系统的遥测数据传感器并不是同时开始工作,为保证输入一致性,缺失的数据用 0 补齐,表示该传感器当前时刻并未启动。

表1 故障检测参数

Tab. 1 Fault detection parameters

参数名称	代码	采样频率/Hz	正常误差范围/%
增压氦气瓶压力/MPa	A	25	± 5
A 氧化剂喷前压力/MPa	B	25	± 5
B 燃料泵壳体温度/°C	O	25	± 8
A 涡轮转速/(r·min ⁻¹)	P	375	± 1.5
B 涡轮转速/(r·min ⁻¹)	Q	375	± 1.5

1.2 数据归一化

本文利用式(1)将数据归一化到[-1,1]区间,使算法对各个参数变化的敏感度接近。

$$y = \frac{2(x - x_{\min})}{x_{\max} - x_{\min}} - 1 \quad (1)$$

式中: x 表示待归一化数据; x_{\min} 表示待归一化数据的最小值; x_{\max} 表示待归一化数据的最大值; y 表示已归一化数据。

燃料箱压正常运行图如图1所示,表示整个故障监测过程燃料箱压相对值。 t 时刻各遥测参数状态图如图2所示,横坐标表示增压输送系统组件代号,纵坐标表示该时刻组件参数的相对值。

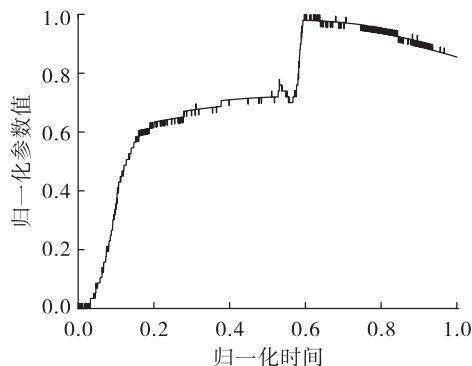
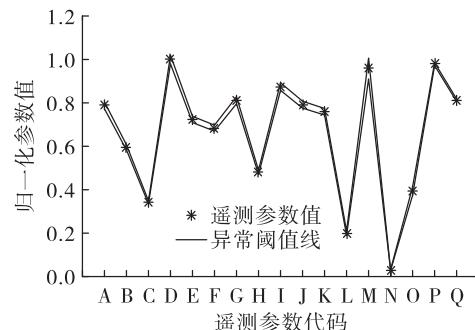


图1 某遥测参数运行图

Fig. 1 Operation of a certain telemetry parameter

对预处理后得到2 000个正常实例,进行标记1代表正常,0代表故障。需要说明的是,本文构建的BP神经网络数据集中的每组实例均具有先后顺序,将抽样点值归一化也作为特殊属性之一输入神经网络进行计算,其代表对应火箭不同时刻的运行状态,减少因火箭工况变化而发生误报的情况。

图2 t 时刻正常遥测参数运行图Fig. 2 Operation of normal telemetry parameters at time t

2 故障模式的数值仿真

火箭试车和发射过程产生的故障数据远少于正常数据,如果直接用于BP神经网络训练,则该故障检测网络无法覆盖所有故障类型,而且不均衡的学习集影响结果准确率。本文在有限的故障数据基础上结合增压输送系统的组件物理关系、专家经验来发现故障模式,进行故障数据的仿真。

2.1 异常和故障模式

液体火箭增压输送系统结构复杂,遥测参数本身具有合理误差范围,超出此误差范围代表系统可能出现异常。

一般而言,当系统某一组件发生异常,该异常数据会在短时间影响其他组件参数,系统多个参数超出合理误差阈值,该种类型的故障需要综合判断多个关键参数才能识别,通常采用专家经验和系统组件的耦合关系发现故障模式并进行故障标记。

2.2 故障数据的数值仿真

本文对于多个遥测参数值超出合理误差范围的故障模式进行数值仿真,仿真故障类型分为随机故障仿真和耦合故障仿真,这两种仿真数据分别使得算法模型对未发生的故障具有一定的敏感性,对已知的故障模式具有较好的检测能力。

对多变量超出合理误差范围的故障类型通过式(2)进行数值仿真

$$x'_t = x_t + w_t \times x_t \quad (2)$$

式中: x_t 表示 t 时刻 x 参数正常运行时的标准值; w_t 表示 t 时刻超出合理误差范围的偏移程度,即故障的严重程度; x'_t 表示 t 时刻 x 参数故障数据。可以根

据需求仿真不同程度的故障。

本文将故障组件和故障程度随机选取,经训练后的神经网络对输入的超过合理误差范围的从未出现过的故障也具有一定的敏感性。模拟 t 时刻组件随机异常状态模拟图如图 3 所示,随机选取 C, F, K 组件出现故障,其值超出异常阈值线。

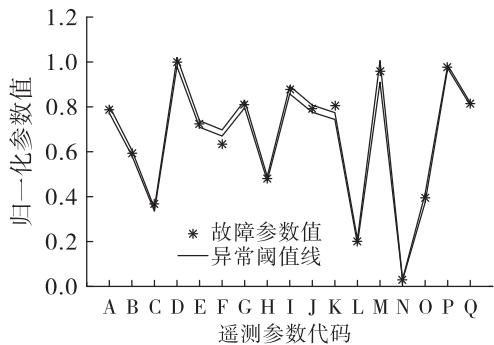


图 3 t 时刻随机故障参数运行图

Fig. 3 Operation of random fault parameters at time t

对于系统耦合故障的仿真要以专家经验和组件的物理关系,确定发生故障时参数相对位置作为故障特征。

如式(3)所示,每个属性添加权重值表示故障程度。式(3)与式(2)的不同之处在于 w 取值是由火箭增压输送系统物理模型和专家经验给出,是在正常误差范围内。

$$\begin{pmatrix} y_1 \\ \vdots \\ y_{18} \end{pmatrix} = \begin{pmatrix} x_1 \\ \vdots \\ x_{18} \end{pmatrix} = \begin{pmatrix} x_1 \times w_1 \\ \vdots \\ x_{18} \times w_{18} \end{pmatrix} \quad (3)$$

耦合故障是根据专家经验和组件物理耦合方式确定故障初期参数变化模式和故障矩阵,增压输送系统常见的 4 种故障模式如下:

1) 贮箱中出现多余物,造成贮箱过滤器堵塞。此类故障直接造成贮箱压力增大,流入液体管道的推进剂减少,导致液体管路增压不足,文氏管前压力降低使得管路推进剂流量进一步减少,供给发动机的推进剂不足,使得泵体壳温度升高、隔离活门前压力减小及组元喷前压力减小。贮箱堵塞故障模式代码为 A1,故障矩阵如式(4)所示,故障模式如图 4 所示。

$$A1 = \begin{pmatrix} 0 & -0.06 & 0 & -0.1 & -0.1 & 0 & 0 \\ -0.08 & 0 & 0.15 & 0 & 0.07 & 0.07 & 0 & 0 & 0 & 0 \end{pmatrix} \quad (4)$$

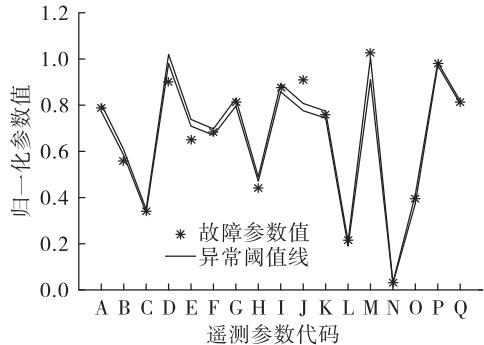


图 4 第 1 200 抽样点发生 A1 故障参数运行图

Fig. 4 Operation of A1 fault parameter at the 1 200th sampling point

2) 增压氦气瓶泄漏故障。氦气瓶泄漏导致氦气瓶失压,管道增压不足导致贮箱压力降低,流入管道的推进剂减少,直接造成涡轮泵转速降低及泵壳体温度升高,其他参数基本不变。增压氦气瓶泄漏故障模式代码为 B1,故障矩阵如式(5)所示,故障模式如图 5 所示。

$$B1 = \begin{pmatrix} -0.15 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.06 & -0.06 & -0.06 & -0.06 & -0.08 & -0.08 & -0.08 & -0.08 & -0.08 & -0.08 & -0.08 & -0.08 \end{pmatrix} \quad (5)$$

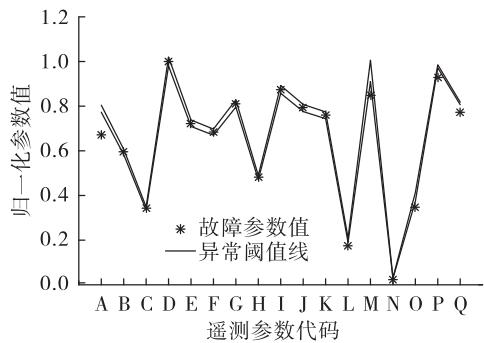


图 5 B1 故障参数运行图

Fig. 5 B1 fault parameter operation

3) 涡轮泵气蚀故障。涡轮气蚀导致转速降低、泵壳温度升高,然后引起组元喷前压力、主文氏管前压力参数下降。其中,涡轮转速、组元喷前压力、主文氏管前压力参数变化明显,其他参数基本不变。涡轮泵气蚀故障代码为 C1,故障矩阵如式(6)所示,故障模式如图 6 所示。

$$C1 = \begin{pmatrix} 0 & -0.15 & -0.15 & -0.12 & -0.12 & -0.15 \\ -0.15 & -0.08 & -0.08 & 0 & 0 & 0.07 \\ 0.07 & -0.05 & -0.05 & 0 & 0 & 0.07 \end{pmatrix} \quad (6)$$

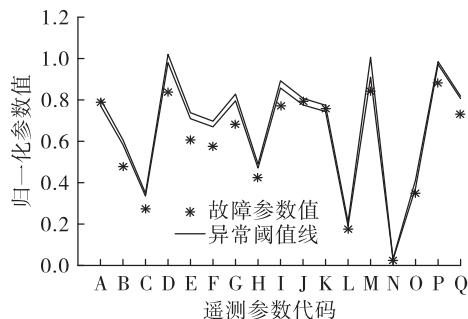


图 6 C1 故障参数运行图

Fig. 6 C1 fault parameter operation

4) 燃气发生器发生燃气泄漏。燃气发生器燃气泄漏首先导致涡轮泵转速降低, 泵壳体温度升高, 组元喷前压力降低, 主文氏管压力降低, 其他参数基本不变。燃气发生器发生燃气泄漏故障代码为 D1, 故障矩阵如式(7)所示, 故障模式如图 7 所示。

$$\begin{aligned} \mathbf{D1} = & (0 \quad -0.12 \quad -0.12 \quad -0.08 \quad -0.08 \quad -0.08 \\ & -0.08 \quad -0.06 \quad -0.06 \quad 0 \quad 0 \quad 0.06 \quad 0.06 \quad 0.06 \\ & 0.06 \quad -0.05 \quad -0.05) \end{aligned} \quad (7)$$

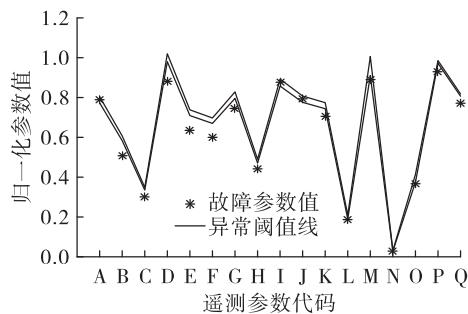


图 7 D1 故障参数运行图

Fig. 7 D1 fault parameter operation

BP 神经网络是一种监督学习网络, 本文通过数值仿真得到的随机故障和 4 种常见故障类型数据实例 500 例, 并添加故障标签, 与正常带标签的 2 000 例数据合并作为后续 BP 神经网络故障检测算法的学习集。

3 神经网络故障分类算法

神经网络是通过调整内部大量节点之间相互连接的关系, 从而达到处理信息的目的, 其具有大规模并行处理、分布式存储、高度冗余和非线性运算能力, 运算速度快, 联想能力较强, 还有较好的容错能力。以上特点对火箭发射时增压和输送系统返回参数这种属性多、规模大、非线性的数据处理有独特的优势。

BP 神经网络主要特点是信号前向传递, 误差反向传播。在前向传递中, 输入信号从输入层经隐含层逐层处理, 直至输出层。每一层的神经元状态只影响下一层神经元状态。如果输出层得不到期望输出, 则转入反向传播, 根据预测误差调整网络权值和阈值, 从而使 BP 神经网络预测输出不断逼近期望输出。

利用 MATLAB 神经网络工具箱构建 BP 神经网络分类模型, 模型参数如表 2 所示。

本文构建的增压输送系统故障检测 BP 神经网络如图 8 所示, 输入层为 181 矩阵, 即 17 个组件参数和时间序列, 输出层为 1 或 0 分别代表正常或故障。隐含层神经元个数为 10, 传递函数为 S 型的正切函数保证了神经网络强大的非线性运算能力, 适用于火箭遥测参数这类非线性数据的计算。

表 2 ANN 分类模型参数

Tab. 2 ANN classification model parameters

神经网络类型	网络层数	传递函数	隐含层神经元数	训练算法	性能函数	自适应学习函数
前馈后向传播网络	2	正切函数	10	BP 训练函数	均方误差	梯度下降动量

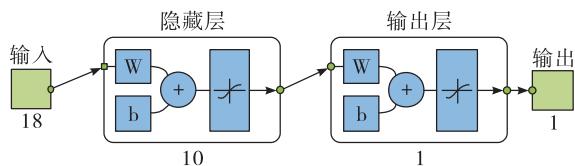


图 8 BP 神经网络示意图

Fig. 8 Schematic diagram of BP neural network

4 算法测试分析

从学习集中均匀抽取 900 条参数实例和标签作为测试集, 剩余 3 600 条数据集数据按照 8:2 划分为训练集和验证集。算法输出结果在区间 [0, 0.5] 标记为异常数据, [0.5, 1] 标记为正常数据。训练

集、测试集检测结果及标签如图 9、图 10 所示。

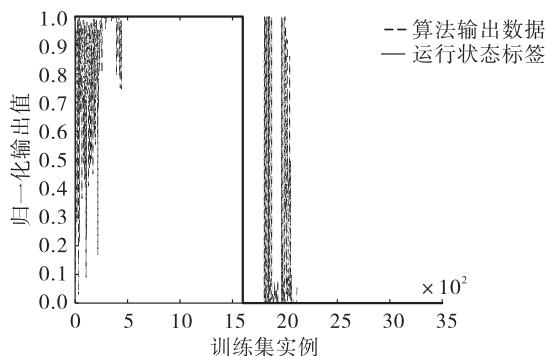


图 9 训练集算法输出值及标签值

Fig. 9 Output value and tag value of training set algorithm

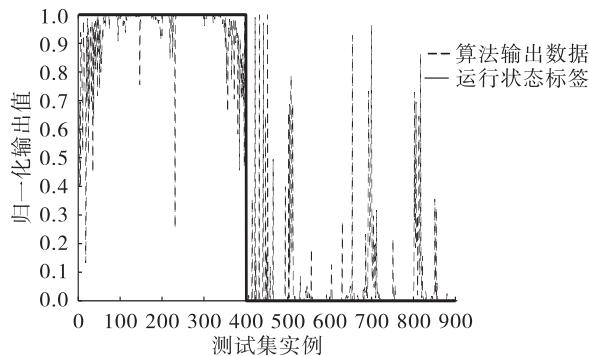


图 10 测试集算法输出值及标签值

Fig. 10 Output value and tag value of test set algorithm

实线为运行状态标签, 标签 1 为正常运行实例, 标签 0 为异常运行实例。虚线为算法输出数据, 其个别输出数据与标签存在差异且超出所设阈值, 则为漏报故障数据和误报正常数据。BP 神经网络故障检测结果如表 3 所示。

表 3 神经网络故障检测结果分析

Tab. 3 Results analysis of neural network fault detection

结果分析	标签实例数		测试实例数		漏报 率/%	误报 率/%
	正常	异常	正常	异常		
训练集	1 600	2 000	1 571	1 924	3.8	1.813
测试集	400	500	390	482	3.6	2.5

由表 3 可得, BP 神经网络故障检测测试集误报率为 2.5%, 漏报率为 3.6%, 可以满足火箭增压输送系统故障检测准确度需求, 在实际应用中, 可以根据火箭具体状况适当调整算法输出结果分类阈

值, 以进一步提高故障检测正确率。

5 结论

本文针对火箭遥测数据规模较大、异常数据较少, 已有的火箭故障检测算法复杂、实时检测能力较差的问题, 提出一种算法简单并具有实时响应能力的液体火箭增压与输送系统的故障检测方法。将预处理后的学习数据划分训练集和测试集输入 BP 神经网络进行训练和测试。测试结果表明: 该算法具有良好的故障检测能力, 误报率和漏报率均很低。由于神经网络可以离线训练的特性及 MATLAB 快速的矩阵运算能力, 采样点计算间隔为毫秒级, 具备故障实时检测的能力。

参考文献:

- [1] 廖少英. 液体火箭推进增压输送系统 [M]. 北京: 国防工业出版社, 2007.
- [2] SCHWABACHER M, WATERMAN R. Pre-launch diagnostics for launch vehicles [C]//2008 IEEE Aerospace Conference. Big Sky, MT, USA: IEEE, 2008: 1-8.
- [3] RODNEY A. Evaluation of anomaly detection capability for ground-based pre-launch shuttle operations [M]//Aerospace Technologies Advancements. [S. l.]: In Tech, 2010.
- [4] FERRELL B, BROWN B, HALL D, et al. Usage of fault detection isolation and recovery (FDIR) in CxP launch operations [C]//SpaceOps 2010 Conference. Huntsville, Alabama. Reston, Virigina: AIAA, 2010.
- [5] SCHWABACHER M, MARTIN R, WATERMAN R, et al. Ares I-X ground diagnostic prototype [C]// Aerospace Conference 2010. Atlanta, Georgia. Reston, Virginia: AIAA, 2010.
- [6] 李艳军. 新一代大推力液体火箭发动机故障检测与诊断关键技术研究 [D]. 长沙: 国防科学技术大学, 2014.
- [7] 陈海峰, 赵政社, 张少博. 基于振动检测的发动机故障诊断算法研究 [J]. 火箭推进, 2012, 38(6): 62-69.
CHEN H F, ZHAO Z S, ZHANG S B. Research on liquid rocket engine fault diagnosisAlgorithm according to vibration detection [J]. Journal of Rocket Propulsion, 2012, 38(6): 62-69.
- [8] 党锋刚, 马红宇, 李春红, 等. 液氧煤油发动机稳态故障仿真分析 [J]. 火箭推进, 2012, 38(2): 27-31.
DANG F G, MA H Y, LI C H, et al. Steady-state fault simula-

- tion and effect analysis of LOX/kerosene rocket engine [J]. Journal of Rocket Propulsion, 2012, 38(2):27-31.
- [9] 孙迪钢. 基于深度学习的轨道转辙机故障检测系统[D]. 广州:华南理工大学, 2018.
- [10] 司佳. 面向工业大数据的智能故障诊断方法研究[D]. 济南:山东大学, 2018.
- [11] 吴建军, 程玉强, 崔星. 液体火箭发动机健康监控技术研究现状[J]. 上海航天(中英文), 2020, 37(1):1-10.
- [12] 李京浩. 基于数据挖掘技术的液体火箭发动机故障检测和诊断研究[D]. 长沙:国防科学技术大学, 2007.
- [13] 张翔, 徐洪平, 安雪岩, 等. 液体火箭发动机稳态运行故障数据聚类分析研究[J]. 火箭推进, 2015, 41(2): 118-122.
ZHANG X, XU H P, AN X Y, et al. Clustering analysis for fault data in steady process of liquid propellant rocket engine [J]. Journal of Rocket Propulsion, 2015, 41 (2) : 118-122.
- [14] 耿辉, 张翔, 张素明, 等. 一种基于聚类分析的液体火箭发动机稳态过程故障诊断方法[J]. 火箭推进, 2014, 40 (5) :86-91.
GENG H, ZHANG X, ZHANG S M, et al. Cluster analysis based diagnosis method for fault in steady process of liquid propellant rocket engine [J]. Journal of Rocket Propulsion, 2014, 40 (5) :86-91.
- [15] 李宁宁. 粒子群算法研究及其在航天发动机健康管理中的应用[D]. 天津:天津理工大学, 2019.
- [16] 谢廷峰, 刘洪刚, 黄强, 等. 液体火箭发动机地面试验车实时故障检测参数的选取[J]. 航天控制, 2008, 26(6): 77-81.
- [17] 黄敏超, 冯心, 张育林. 应用神经网络识别液体火箭发动机的故障模式[J]. 推进技术, 1993, 14(6):32-38.
- [18] 黄敏超, 张育林, 陈启智. 动态神经网络在液体火箭发动机故障检测与分离中的应用[J]. 航空动力学报, 1996, 11(2):149-152.
- [19] WHEELER K, DHAWAN A, MEYER C. SSME sensor modeling using radial basis function neural networks [C]//30th Joint Propulsion Conference and Exhibit. Indianapolis, IN. Reston, Virginia: AIAA, 1994.