

一种液体火箭发动机试车启动过程故障预警方法*

高 创¹, 陈立平¹, 梅再武²

1. 华中科技大学机械科学与工程学院, 武汉 430070

2. 苏州同元软控信息技术有限公司, 苏州 215000



摘 要 针对某液体火箭发动机地面试车启动过程中故障样本数据稀少、故障预测和故障部件定位等问题, 提出了一种基于注意力机制的卷积神经网络和长短时记忆网络的故障预警方法。首先, 搭建了液体火箭发动机系统仿真模型, 采用参数故障注入方法获取启动阶段的正常/故障样本; 其次, 通过卷积神经网络从输入样本中捕获局部特征, 利用长短时记忆网络从特征中提取时序特征, 进而预测出监测参数的潜在变化趋势; 最后, 基于故障诊断模型定位故障部件, 实现发动机启动过程的故障预警。实验结果表明, 该方法能够有效地对该火箭发动机启动阶段故障进行预警, 具有工程应用价值。

关键词 液体火箭发动机; 故障预警; 卷积神经网络; 长短时记忆网络

中图分类号: V434 **文献标识码:** A

文章编号: 1006-3242(2023)05-0074-06

A Fault Warning Method for Start-up Process of Liquid Rocket Engine Test

Gao Chuang¹, Chen Liping¹, Mei Zaiwu²

1. School of Mechanical Science and Engineering, Huazhong University of Science and
Technology, Wuhan 430070, China

2. Suzhou Tongyuan Software & Control Technology Co., Ltd., Suzhou 215000, China

Abstract Aiming at the problems of scarcity of fault sample data, fault prediction and fault component localization during the ground test process of a liquid rocket motor, a fault warning method based on convolutional neural network and long short-term memory network on attention mechanism is proposed. Firstly, a simulation model of the liquid rocket engine system is built, and the normal/fault samples of the start-up phase are obtained by parameter fault injection. Secondly, the convolutional neural network is used to capture local features from the input samples, and the long short-term memory network is used to extract time series characteristics from the features, thereby predicting the potential degradation trend of the monitoring parameters. Finally, based on the fault diagnosis model that locates the faulty parts, the fault warning is realized during the engine starting process. The experimental results show that the failure of the rocket en-

* 国家重点研发计划(2019YFB1706501)

收稿日期: 2023-03-17

作者简介: 高 创(1999-), 男, 硕士研究生, 主要研究方向为多领域建模仿真与故障检测, E-mail: 18815695770@163.com; 陈立平(1964-), 男, 教授, 主要研究方向为几何约束求解、多体系统动力学和多领域建模分析数字化设计支撑技术, 本文通信作者; 梅再武(1987-), 男, 博士研究生, 主要研究方向为多领域统一建模及工程应用与机理-数据混合建模。

gine can be effectively warned by using this method in the start-up stage that can serve as reference for engineering application.

Key words Liquid rocket engine; Fault warning; Convolutional neural network; Long short-term memory network

0 引言

液体火箭发动机作为运载火箭系统飞行动力的核心,决定着运载火箭的整体性能,直接关系到航天任务的成败^[1]。由于发动机的复杂耦合系统和极端工作环境,任何微小的异常都可能迅速发展为破坏性故障,导致发射任务失败,造成巨大的经济损失。因此,液体火箭发动机故障检测与诊断的研究受到广泛关注^[2]。

从20世纪70年代起,美国开始研发各种发动机故障检测与诊断系统,如红线系统(RS)广泛应用于航天航空领域^[3],后续研发了异常故障检测系统(SAFD),实时监测发动机的24个变量,并配套数据筛选和专家诊断系统,用于火箭发动机飞行和试车后的故障检测^[4]。在几十年的发展过程中,我国的液体火箭发动机故障检测技术取得了瞩目的成绩,研制了基于信号的故障检测方法、基于专家知识的故障诊断方法、基于模糊理论的健康监测技术等^[5],但传统的人工智能方法在实际应用中,往往取决于工作人员的专业知识和工程经验,与国外的智能检测发展存在一定的差距。

传统的智能检测方法由于其对系统复杂数据特征的学习能力差,限制了其对故障的预测及诊断,深度学习凭借其强大的特征学习和非线性表达能力,在图像处理、语音识别等领域得到广泛应用,逐渐成为智能故障检测与诊断的主要手段。火箭发动机故障检测的方法已经从单一算法检测转向多算法融合检测,从传统的基于传感器的诊断转向基于深度学习的故障检测。徐亮等^[6]提出一种改进粒子群优化的小波神经网络模型,将其应用于火箭发动机的故障检测研究。邓晨等^[7]针对大推力氢氧补燃循环发动机的主级工况,设计了基于ARMR模型的实时故障诊断算法,并改进了阈值求解方法以及故障判别准则。

目前相关的研究大多是基于发动机已有数据的故障诊断,缺少对发动机的预测性维护,即提前

预测可能会发生故障的部件。因此,本文提出了一种基于注意力机制的CNN-LSTM的故障预警方法,用于发动机地面试车启动过程的故障检测及预警中。

1 发动机故障仿真模型

火箭发射前必须进行地面测试,以提高火箭发射成功率。由于地面试验过程复杂、费用昂贵,且地面试验数量的有限性^[8],很难收集到系统在故障状态下的响应数据。

本文借助苏州同元软控信息技术有限公司开发的MWORKS软件,通过模块化建模仿真技术,采取参数故障注入方式获得系统对所注入的故障的反应信息和输出信号^[9],探究可能的故障模式,扩充故障样本数据集,用于发动机的故障预警研究。

1.1 发动机故障及监测参数

根据液体火箭发动机启动过程中各典型部件的功能结构、性能特性及数学表达^[10],建立了发动机典型部件模型。采用参数故障注入方式,设计了燃烧室故障(泄漏)、喷管故障(喉部烧蚀)、涡轮故障(叶片烧蚀、流道阻塞)和离心泵故障(叶轮损坏)的5个固有故障(F01-F05),以及正常状态(F06),具体如表1所示。

表1 故障部件及类型

发动机/部件	故障编号	故障/正常状态
燃烧室	F01	燃烧室泄露
喷管	F02	喉部烧蚀
燃气涡轮	F03	叶片烧蚀
	F04	流道阻塞
离心泵	F05	叶轮损坏
发动机	F06	正常状态

本文只考虑与上述故障相关的监测参数,通过对关键参数的测量,模拟出发动机运行过程中的物理状态。通过特征选择,确定选取监测的参数(SF01-SF09),在表2中详细说明。在启动过程中,若能提前检测到发动机的异常行为,可以展开针对

性预测维护,保护发动机和地面测试设施,最大限度地减少故障的潜在损害。

表 2 故障监测参数

监测部件	监测参数编号	参数
燃烧室	SF01	燃烧室压力
	SF02	燃烧室入口温度
喷管	SF03	喷管入口温度
	SF04	喷管出口压力
氢侧泵	SF05	氢侧泵入口压力
	SF06	氢侧泵出口压力
氧侧泵	SF07	氧侧泵入口压力
	SF08	氧侧泵出口压力
燃气发生器	SF09	燃气发生器压力

1.2 发动机部件故障模型

涡轮泵是液体火箭发动机内最复杂的组件之一,它的动态特性对发动机的动态特性具有重要影响。本文以涡轮泵故障仿真为例,燃气涡轮叶片烧蚀的故障表达公式如下:

$$q_{mT} = \begin{cases} C_T \sqrt{\frac{2\gamma_T}{\gamma_T - 1} \left(\left(\frac{P_{eT}}{P_{iT}} \right)^{\frac{2}{\gamma_T}} - \left(\frac{P_{eT}}{P_{iT}} \right)^{\frac{\gamma_T+1}{\gamma_T}} \right)}, & \frac{P_{eT}}{P_{iT}} > \left(\frac{2}{\gamma_T + 1} \right)^{\frac{\gamma_T}{\gamma_T-1}} \\ C_T \sqrt{\gamma_T \left(\frac{2}{\gamma_T + 1} \right)^{\frac{\gamma_T+1}{\gamma_T-1}}}, & \frac{P_{eT}}{P_{iT}} \leq \left(\frac{2}{\gamma_T + 1} \right)^{\frac{\gamma_T}{\gamma_T-1}} \end{cases} \quad (1)$$

$$C_T = \frac{F_{IA} C_{dT} A_T P_{iT}}{\sqrt{R_{gT} T_{iT}}} \quad (2)$$

式中: q_{mT} 为涡轮流量, C_T 为系数, C_{dT} 为涡轮喷嘴的流量系数, A_T 为涡轮喷嘴的最小流通面积, R_{gT} 为工质气体常数, T_{iT} 为涡轮入口温度, γ_T 为涡轮氢比热比, P_{eT} 和 P_{iT} 分别为涡轮出口和入口压力, F_{IA} 表示叶片烧蚀故障因子,正常时 $F_{IA} = 1$,发生故障时 $0 \leq F_{IA} < 1$ 。

2 算法介绍

2.1 长短时记忆网络

循环神经网络(RNN)是一种专用于处理序列信息的人工神经网络,通过存储过去输入的单元影响输出。长短时记忆网络(LSTM)是RNN的一种特殊类型,可以有效解决RNN梯度消失的问题。LSTM引入了输入门、输出门和遗忘门,有效地防止了各种顺序模型的长期依赖性。描述某时刻 t 的LSTM基本单元的方程为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (7)$$

$$h_t = o_t \tanh(C_t) \quad (8)$$

式中: W 为网络层权重, b 为网络层偏置项, f 为遗忘门, i 为输入门, o 为输出门, x_t 为 t 时刻的输入, C_t 为 t 时刻单元状态, h_t 为 t 时刻输出隐藏状态, \tilde{C}_t 为更新的输入状态,以上变量均为矩阵形式; σ 表示sigmoid函数,输出范围为(0,1),计算公式为 $\sigma(x) = 1/(1 + e^{-x})$, \tanh 为双曲正切函数,输出范围为(-1, 1),计算公式为 $\tanh(x) = (e^x - e^{-x})/(e^x + e^{-x})$ 。

2.2 注意力机制

利用卷积网络进行特征提取时往往会忽略非局部区域的信息,而注意力机制(Attention)可以有效地进行这些非局部区域的信息融合,以概率图或概率特征向量的形式表示^[11]。注意力机制的工作过程分为3个阶段:1)对输入特征和标签进行相似度计算;2)将得到的权值进行归一化处理,对输入特征配以不同权重;3)进行加权求和输出结果。

$$f_{\text{Attention}} = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

式中: $f_{\text{Attention}}$ 为 Attention 层输出的特征向量, V 是表示输入的特征向量, Q 和 K 是计算权重的特征向量, d_k 为缩放系数, softmax 为非线性转换函数,输出为概率分布。

2.3 液体火箭发动机故障诊断模型

本文搭建的CNN-LSTM-Attention故障诊断模型结构如图1所示。模型进行训练前,首先预处理数据,设置采样步长和滑动窗口大小,将监测参数多维特征划分为多个时序样本,CNN层用于提取数据的局部特征。为避免CNN层对模型造成过拟合现象,将CNN输出的特征信息输入到LSTM层中,提取特征的时序信息。其次,通过Attention层对时序信息的权重进行重新分配,将模型的注意力集中在多维特征中更重要的特征信息上。最后,利用全连接网络输出故障概率,实现故障部件的定位。

2.4 液体火箭发动机故障预警流程

本文将发动机启动阶段的故障预警分为故障预测和故障诊断。图2为液体火箭发动机故障预警流程,其步骤如下:

1) 采取故障注入方法得到监测参数的正常样本和故障样本,用于故障预测和诊断模型的训练;

2) 划分预测模型的训练集、验证集和测试集, 探究不同长度的窗口组合对预测精度的影响, 选取较优的组合, 保存 CNN-LSTM 预测模型;

3) 确定诊断性能评价标准, 选取较优的诊断模型, 保存故障诊断模型;

4) 划分预警测试样本, 选取 1~3 s 的监测数据作为预测模型的输入, 得到 3~4 s 预测数据;

5) 组合真实数据和预测数据, 划分样本并打乱标签, 输入到诊断模型中, 得到部件故障概率, 定位故障部件。




图1 CNN-LSTM-Attention 故障诊断模型结构

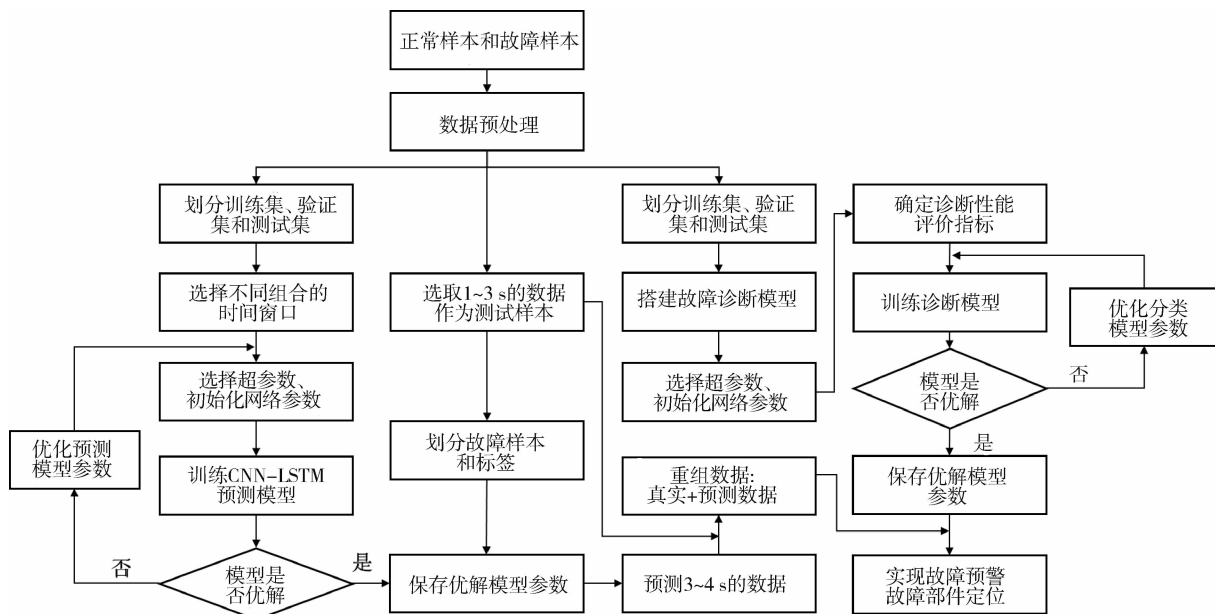


图2 液体火箭发动机故障预警流程

3 仿真校验

3.1 发动机早期故障预测

3.1.1 评价标准

选取均方根误差和决定系数作为模型评价标准, 用来评价发动机故障预测模型的性能。

1) 均方根误差

$$e_{\text{RMSE}} = \sqrt{\frac{1}{l} \sum_{i=1}^l (\hat{y}_i - y_i)^2} \quad (10)$$

式中: e_{RMSE} 为均方根误差, l 为样本的大小, \hat{y}_i 为第 i

个数据的预测值, y_i 为第 i 个数据的真实值。

2) 决定系数

$$\bar{y} = \frac{1}{l} \sum_{i=1}^l y_i \quad (11)$$

$$R^2 = \frac{\sum_{i=1}^l (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^l (y_i - \bar{y})^2} \quad (12)$$

式中: R^2 为决定系数, \bar{y} 为真实数据平均值。

3.1.2 故障预测结果

模型的输入为时间序列多维数据, 采样步长为 1, 为探究滑动窗口大小对于预测性能的影响, 本文选取 5 种组合: 60×9 、 80×9 、 100×9 、 120×9 和

150 × 9, 表 3 显示了不同窗口的均方根误差和决定系数, 结果表明 120 × 9 相比于其他组合, 测试集的均方根误差低于其他组合, 决定系数更贴近 1, 能较好地预测出参数变化趋势。

表 3 不同组合窗口的性能评价

样本名称 窗口大小	训练集 均方根误差	训练集 决定系数	测试集 均方根误差	测试集 决定系数
60 × 9	0.017905	0.978355	0.018782	0.971054
80 × 9	0.013419	0.986849	0.013998	0.982532
100 × 9	0.008952	0.992807	0.009402	0.988359
120 × 9	0.006669	0.996011	0.006708	0.995508
150 × 9	0.010689	0.989619	0.011164	0.986730

图 3 为 120 × 9 窗口下燃烧室压力值的前 250 个样本预测结果, 从图 3(a) 和 (b) 可知模型拟合效果较好, 训练集和测试集的预测结果与真实结果无明显差异, 图 3(c) 表明模型经过迭代, 不断趋于稳定并收敛, 证明了模型的可行性。




图 3 120 × 9 窗口下的 0 ~ 250 个样本预测结果

3.2 发动机故障诊断

3.2.1 评价标准

本文采用准确率 (A_1)、精确率 (P_1)、召回率 (R_1) 和 F-score (F_1) 等指标来量化模型, 评价诊断模型的性能, 公式如下:

$$A_1 = \frac{(T_P + T_N)}{(T_P + T_N + F_P + F_N)} \quad (13)$$

$$P_1 = \frac{T_P}{T_P + F_P} \quad (14)$$

$$R_1 = \frac{T_P}{T_P + F_N} \quad (15)$$

$$F_1 = (1 + \beta^2) \frac{P_1 \times R_1}{\beta^2 \times P_1 + R_1} \quad (16)$$

式中: T_P 为某一故障被正确分类的数量, T_N 为其他故障被正确分类的数量, F_P 为其他故障被错误分类的数量, F_N 为某一故障被错误分类的数量, β 为相关参数。

3.2.2 故障诊断结果

为增强实验结果的可靠性, 本文对提出的故障诊断模型进行 10 次实验, 将其平均值作为性能的评估指标, 计算得到测试集的准确率为 97.58%, 精确率为 97.68%, 召回率为 97.58%, F-score 为 97.58%, 其中燃烧室泄露准确率为 90%、喷管烧蚀准确率为 96%, 涡轮叶片烧蚀、涡轮流道堵塞、离心泵叶轮损坏以及正常状态的准确率均为 100%, 图 4 为 CNN-LSTM-Attention 诊断模型训练过程中准确率的变化, 从中可以看出准确率经过多次迭代后接近于 1, 并趋于稳定, 说明本文的诊断模型能有效识别启动阶段故障特征, 具有良好的分类效果。




图 4 CNN-LSTM-Attention 诊断模型准确率曲线

3.3 发动机故障预警

选取正常样本和 5 种故障样本, 对启动阶段前 1 ~ 3 s 的数据采取滑动窗口划分, 将其作为 CNN-LSTM 预测模型的输入, 得到 3 ~ 4 s 的预测数据,

CNN-LSTM-Attention 诊断模型的输入为组合数据,模型输出结果为故障概率,图5为故障预警模型的混淆矩阵,图中对角线数值为故障预警的准确率,在测试样本上,发动机故障预警准确率为96.21%,在一定程度上可以对液体火箭发动机故障进行预测性诊断,实现了潜在故障部件的定位。

F01	0.96	0.02	0.00	0.02	0.00	0.00
F02	0.00	1.00	0.00	0.00	0.00	0.00
F03	0.00	0.00	1.00	0.00	0.00	0.00
F04	0.05	0.00	0.00	0.85	0.00	0.10
F05	0.00	0.00	0.03	0.00	0.97	0.00
F06	0.00	0.00	0.00	0.00	0.00	1.00
	F01	F02	F03	F04	F05	F06

图5 故障预警模型混淆矩阵

4 结论

针对某液体火箭发动机地面试车启动过程的故障预警,提出了一种基于注意力机制的CNN-LSTM的预警方法。通过搭建发动机故障模型,批量仿真获取正常以及故障样本。建立故障预测模型,用于预测监测参数的变化趋势。利用故障诊断模型,实现对预测数据的诊断,定位故障部件。实验结果表明:本文提出的预警方法能较好地识别火箭发动机启动阶段的工作状态,技术人员可通过对故障概率较高的部件进行检修和维护,缩短维护周期,保障生命和财产安全。

参 考 文 献

- [1] 张振臻,陈晖,高玉闪,等. 液体火箭发动机故障诊断技术综述[J]. 推进技术,2022,43(6):20-38. (Zhang Zhenzhen, Chen Hui, Gao Yushan, et al. Review on fault diagnosis technology of liquid rocket engine [J]. Journal of Propulsion Technology, 2022, 43(6):20-38.)
- [2] Zhu X, Cheng Y, Wu J, et al. Steady-state process fault detection for liquid rocket engines based on convolutional auto-encoder and one-class support vector machine [J]. IEEE Access, 2019, 8: 3144-3158.
- [3] Hawman M. Health monitoring system for the SSME-program overview [C]//26th Joint Propulsion Conference, Orlando, FL, USA, July 16-18, 1990.
- [4] Tsutsumi S, Hirabayashi M, Sato D, et al. Data-driven fault detection in a reusable rocket engine using bivariate time-series analysis [J]. Acta Astronaut. 2021, 179: 685-694.
- [5] 吴建军,朱晓彬,程玉强,等. 液体火箭发动机智能健康监控技术研究进展[J]. 推进技术, 2022, 43(1): 7-19. (Wu Jianjun, Zhu Xiaobin, Cheng Yuqiang, et al. Research progress of intelligent health monitoring technology for liquid-propellant rocket engines [J]. Journal of Propulsion Technology, 2022, 43(1):7-19.)
- [6] 许亮,马硕,薛薇,等. 改进 PSO 优化 WNN 的液体火箭发动机故障检测[J]. 航天控制, 2021, 39(4):74-80. (Xu Liang, Ma Shuo, Xue Wei, et al. Improved PSO and optimized WNN for liquid rocket engines fault detection [J]. Aerospace Control, 2021, 39(4):74-80.)
- [7] 邓晨,薛薇,郑孟伟,等. 基于改进 ARMA 模型的火箭发动机稳态工况过程实时故障诊断方法研究[J]. 计算机测量与控制, 2020, 28(2):33-38. (Deng Chen, Xue Wei, Zheng Mengwei, et al. Study on real-time diagnosis method of the main stage working condition of rocket engine based on improved ARMA model [J]. Computer Measurement & Control, 2020, 28(2):33-38.)
- [8] 朱明清. 基于 Modelica 的液体火箭推进系统故障仿真及系统实现 [D]. 武汉:华中科技大学,2016. (Zhu Mingqing. Fault simulation and software development of liquid rocket propulsion system based on Modelica [D]. Wuhan: Huazhong University of Science and Technology, 2016.)
- [9] 赵建军,丁建完,周凡利,等. Modelica 语言及其多领域统一建模与仿真机理 [J]. 系统仿真学报, 2006 (S2): 570-573. (Zhao Jianjun, Ding Jianwan, Zhou Fanli, et al. Modelica and its mechanism of multi-domain unified modeling and simulation [J]. Journal of System Simulation, 2006(S2):570-573.)
- [10] 薛薇,武小平,张箭,等. 基于 RESID 方法的液体火箭发动机实时故障诊断算法设计及半实物仿真验证 [J]. 计算机测量与控制, 2022, 30(9):17-21. (Xue Wei, Wu Xiaoping, Zhang Jian, et al. Based on the RESID model for the liquid rocket propulsion fault detection and the hil test [J]. Computer Measurement & Control, 2022, 30(9):17-21.)
- [11] 王璐,姚宇. 基于特征融合和注意力机制的超声影像分割网络 [J]. 计算机应用, 2022, 42 (S2): 230-236. (Wang Lu, Yao Yu. Ultrasound image segmentate on network based on feature fusion and attention mechanism [J]. Journal of Computer Applications, 2022, 42(S2): 230-236.)