

Wasserstein 距离在液体火箭发动机故障检测中的应用*

程玉强, 邓凌志

(国防科技大学 空天科学学院, 湖南 长沙 410073)

摘要: 健康监控技术能够切实提高液体火箭发动机的可靠性, 针对液体火箭发动机健康监控中的故障检测问题, 提出基于 Wasserstein 距离的方法, 利用液氢液氧火箭发动机地面热试车数据进行验证。该方法的核心思想是利用 Wasserstein 生成对抗网络模拟正常数据的样本分布, 利用其判别器计算测试样本与模拟分布间的 Wasserstein 距离, 进而实现故障检测。结果表明: 该方法能够克服故障数据不足的困难, 有效检测稳态过程中的故障, 没有发生误报警, 且对早期异常有较高敏感性; 在训练样本较少的情况下, 当 Wasserstein 距离阈值为 3σ 时对启动过程的早期异常有较高敏感性, 取 5σ 时仍可有效检测启动过程中的故障, 误报警率为 12.5%。

关键词: 液体火箭发动机; 故障检测; Wasserstein 距离; 生成对抗网络

中图分类号: TP316 **文献标志码:** A **开放科学(资源服务)标识码(OSID):**

文章编号: 1001-2486(2023)04-020-08



听语音
与作者互动
聊科研

Application of Wasserstein distance in fault detection for liquid-propellant rocket engines

CHENG Yuqiang, DENG Lingzhi

(College of Aerospace Science and Engineering, National University of Defense Technology, Changsha 410073, China)

Abstract: Health monitoring can effectively improve the reliability of liquid-propellant rocket engines. Aiming at the problem of fault detection in health monitoring for liquid-propellant rocket engines, a method based on Wasserstein distance was proposed and verified using ground hot test data of an LOX/LH₂ rocket engine. The core idea was to use Wasserstein generative adversarial network to simulate the sample distribution of normal data, and used its discriminator to calculate the Wasserstein distance between the test sample and the simulated distribution, so as to achieve fault detection. The results show that the proposed method can overcome the difficulty of insufficient fault data, detect the faults in the steady-state process effectively without false alarm, and is sensitive to early anomalies. In the case of a small number of training samples, when the Wasserstein distance threshold is set to 3σ , the method is sensitive to early anomalies during the start-up transient. Starting fault can still be effectively detected with the threshold of 5σ , with a false alarming rate of 12.5%.

Keywords: liquid-propellant rocket engine; fault detection; Wasserstein distance; generative adversarial network

液体火箭发动机 (liquid-propellant rocket engine, LRE) 作为运载火箭的主要动力装置, 其可靠性关系着航天任务的成败。然而, LRE 的结构复杂且工作在高温高压的极致环境中, 其发生故障的概率较高, 严重的发动机故障往往会造成很严重的后果^[1]。发展 LRE 健康监控技术, 能够有效提高运载火箭的安全性和可靠性。

故障检测与诊断 (fault detection and diagnosis, FDD) 方法是 LRE 健康监控技术的核心与基础。根据使用的信息类型和采用的故障搜索策略^[2], FDD 方法可以分为基于模型、基于信号处理和基于人工智能的方法。基于模型的方法通

过比较系统的实际测量输出与模型预测输出之间的一致性来进行 FDD^[3], 其代表性方法是卡尔曼滤波算法。董立宝等^[4]将集合卡尔曼滤波算法应用于发动机启动瞬态状态监测, Lee 等^[5]将基于微分方程的卡尔曼滤波器应用于开式循环 LRE 的稳态过程 FDD, Cha 等^[6]将非线性卡尔曼滤波方法应用于开式循环 LRE 的瞬变过程 FDD。此外, 研究人员还开发了基于 H_∞ 理论^[7]、机电制动力器^[8]、多元线性回归算法^[9]的方法。该类方法解释性强并具有检测未知故障的能力, 但精确建模困难、泛化性能较差, 难以满足实际需求。基于信号处理的方法主要依靠工程经验和专家知识对

* 收稿日期: 2023-03-13

基金项目: 国家自然科学基金创新研究群体资助项目 (T2221002)

作者简介: 程玉强 (1979—), 男, 湖南长沙人, 研究员, 博士, 硕士生导师, E-mail: 20125275@qq.com;

邓凌志 (通信作者), 男, 湖北洪湖人, 博士研究生, E-mail: denglingzhi@nudt.edu.cn

测量信号进行特征提取,然后根据故障特征分析和对健康系统特征的先验知识做出检测和诊断决策。该类方法主要有统计特征分析^[10]、小波方法^[11]、应力波检测技术^[12]等。该类方法简单直观,但严重依赖专家经验且精度较低。基于人工智能的方法主要可以分为基于专家系统的方法、基于统计可靠性的方法和基于深度学习的方法。基于专家系统的方法通过模拟专家的决策来检测和诊断发动机故障,如用于 Titan 第一级发动机验收试验和例行数据分析的 Titan 健康评估专家系统 (Titan health assessment expert system, THAES)^[13]。基于统计可靠性的方法主要以机器学习为主要工具来提取能够表示系统变量依赖性的“底层知识”,代表性的方法有模糊聚类^[14]、支持向量机 (support vector machine, SVM)^[15]、主成分分析^[16]等。基于深度学习的方法主要是利用人工神经网络 (artificial neural network, ANN) 从样本中自主学习,找到样本数据之间的映射关系,如卷积自编码器 (convolutional auto-encoder, CAE)^[1]、反向传播神经网络 (back propagation neural network, BPNN)^[17]、长短期记忆 (long short-term memory, LSTM) 网络^[18]等。该类方法受传感器数据的规模和质量影响较大,且解释性差。

上述方法大多依赖故障数据或专家经验,然而 LRE 的实验数据大多数都是正常数据,故障样本稀缺。为了寻求一种较为简便且不依赖于故障数据的方法,本研究以氢氧火箭发动机为研究对象,提出基于 Wasserstein 距离的故障检测方法。

1 Wasserstein 生成对抗网络原理

简要介绍生成对抗网络 (generative adversarial network, GAN) 的基本原理。GAN 是通过对抗过程估计生成模型的框架^[19],无须先验概率建模,就能学习真实的样本分布。GAN 由生成器和判别器两部分组成,这两部分均由神经网络构成。GAN 的原理及训练流程如图 1 所示,生成器的作用是将输入的噪声信号通过神经网络映射到样本空间,输出尽可能真的假样本,而判别器的作用则是判断样本是来自生成器的假样本还是来自真实数据分布的真样本。GAN 训练过程中,二者交替优化,通过生成器与判别器相互博弈,达到纳什均衡,最终使生成器生成的样本符合真实样本概率分布。

生成器的训练过程如下:向生成器输入随机噪声,输出生成样本,向判别器输入生成样本,输出判别结果,计算误差,更新生成器的网络权值。

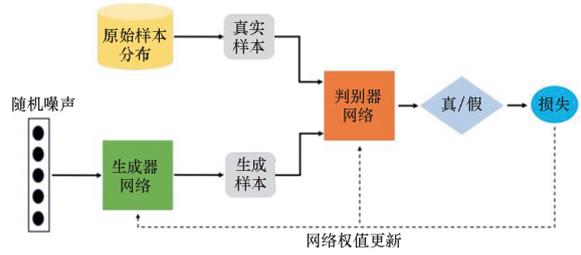


图 1 GAN 的原理及训练流程

Fig. 1 Principle and training process of GAN

判别器的训练过程如下:向判别器输入生成样本和真实样本,输出判别结果,计算误差,更新判别器的网络权值。两者交替进行,达到设定的训练轮数或一定条件,训练完成。GAN 训练完成后,生成器能够很好地估计原始样本的概率分布,并生成符合原始样本分布的新样本,判别器的作用则是判断样本的真假。

GAN 存在训练不稳定、模式崩溃、训练程度不明等问题,为了解决这些问题,Arjovsky 等^[20]提出了 Wasserstein 生成对抗网络 (Wasserstein generative adversarial network, WGAN),以 Wasserstein 距离来度量两个样本分布之间的差异。Wasserstein 距离又叫推土机距离 (earth mover's distance, EMD),如图 2 所示,假设样本分布为土堆的形状,现需将一个土堆通过推土的方式转化为另一个土堆,EMD 就是实现该过程所需的最小工作量,其计算方法是泥土的质量乘以其移动的距离。

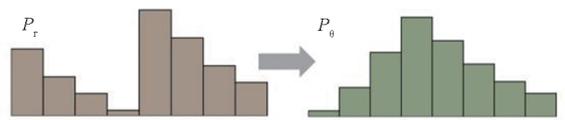


图 2 推土机距离示意图

Fig. 2 Diagram of earth mover's distance

EMD 的数学形式为:

$$W(P_r, P_0) = \inf_{\gamma \in \Pi(P_r, P_0)} E_{(x,y) \sim \gamma} [\|x - y\|] \quad (1)$$

其中, P_r 和 P_0 为两个样本分布, $\Pi(P_r, P_0)$ 为 P_r 和 P_0 组成的所有可能的联合分布的集合, γ 为 x 与 y 的联合分布, $(x, y) \sim \gamma$ 表示从联合分布 γ 中采样得到样本 x 与 y , $\|x - y\|$ 为 x 与 y 间的距离,所有可能的联合分布中期望值的下确界 $\inf_{\gamma \in \Pi(P_r, P_0)} E_{(x,y) \sim \gamma} [\|x - y\|]$ 即为 EMD。

为了适应于神经网络的训练,将 EMD 近似为:

$$W(P_r, P_0) = \sup_{\|f\|_L \leq 1} E_{x \sim P_r} [f(x)] - E_{y \sim P_0} [f(y)] \quad (2)$$

其中, $\|f\|_L$ 表示函数 f 的 Lipschitz 常数。

生成器和判别器的损失函数的计算方法为:

$$L_G = -E_{x \sim P_0}[f(x)] \quad (3)$$

$$L_D = E_{x \sim P_0}[f(x)] - E_{x \sim P_1}[f(x)] \quad (4)$$

WGAN 训练完成后,生成器能够很好地模拟训练集的样本分布,生成符合原始样本分布的新样本,判别器可以计算测试样本与模拟分布间的 EMD。

WGAN 彻底解决了训练不稳定的问题,不再需要小心平衡生成器和判别器的训练程度;基本解决了模式崩溃的问题,确保了生成样本的多样性;训练过程中以 EMD 指示训练进程。WGAN 在结构上与 GAN 没有本质区别,易于实现。其主要区别在于 WGAN 判别器的输出结果是输入样本与模拟分布间的 EMD,故判别器的输出层不使用激活函数,生成器和判别器的损失不取对数,判别器的参数在每次更新之后截断到一个范围。

2 基于 Wasserstein 距离的故障检测方法

WGAN 的判别器可以计算测试样本与模拟分布间的 EMD,故障样本与正常样本的 EMD 应当存在一定差异性,利用该原理实现故障检测。

基于 Wasserstein 距离的故障检测方法流程如图 3 所示。首先,对 LRE 试车数据进行预处理,划分数据集;其次,利用仅有正常样本构成的训练集训练 WGAN 模型;然后,用判别器计算训练集样本与模拟分布间的 EMD,计算 EMD 的故障阈值;最后,用判别器计算测试集的 EMD 并与

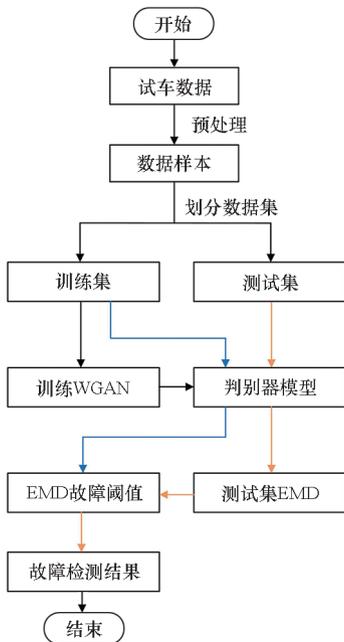


图 3 基于 EMD 的故障检测方法流程

Fig. 3 Process of EMD-based fault detection method

EMD 阈值进行比较,得到检测结果。

3 火箭发动机试车数据验证与分析

3.1 研究对象及数据预处理

LRE 系统如图 4 所示,以大型泵压式液氢液氧火箭发动机为研究对象,对基于 Wasserstein 距离的故障检测方法进行验证与分析。本文使用的数据共包括 8 次正常试车数据、4 次稳态过程故障试车数据和 2 次启动过程故障试车数据,共计 14 次试车数据,如表 1 所示。

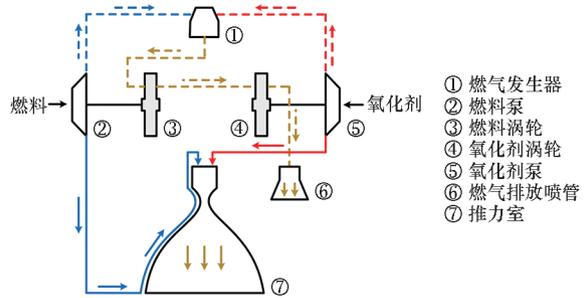


图 4 LRE 系统简图

Fig. 4 Diagram of an LRE system

表 1 LRE 地面试车情况统计

Tab. 1 Statistics of ground tests of an LRE

运行情况	试车编号
正常	Test 01, Test 02, Test 03, Test 04 Test 05, Test 06, Test 07, Test 08
稳态故障	Test 11, Test 12, Test 13, Test 14
启动故障	Test 21, Test 22

采集的试车数据包括 22 个参数,采样率为 50 Hz,参数类型包括压力、温度、质量流量和转速,参数数量级范围为 $10^{-1} \sim 10^4$ 。对原始数据进行归一化预处理,将其转化为大小更一致、更加规范的样本,降低模型复杂度,提高模型泛化性能。其计算方法为:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

其中, x 为原始参数, x_{\max} 和 x_{\min} 分别为该参数的最大值和最小值, y 为归一化后的参数。

3.2 稳态过程故障检测

截取正常试车和稳态故障试车的稳态过程数据以进行稳态过程故障检测,将正常试车数据的 90% 样本划分为训练集,正常试车数据的 10% 样本与故障试车的所有样本划分为测试集,各数据集的分布情况如图 5 所示。

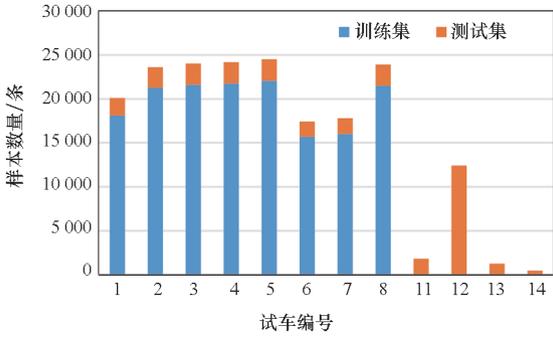


图5 稳态过程数据集的划分方案

Fig.5 Partition scheme of steady-state process data set

接下来构建 WGAN 模型。使用多层感知机 (multilayer perceptron, MLP) 构成生成器和判别器, 生成器的输入参数和输出参数为发动机的 22 个参数, 设置 1 个隐藏层, 隐藏层由 22 个神经元构成, 隐藏层的激活函数为 LeakyReLU 函数, 输出层的激活函数为 sigmoid 函数; 判别器的输入参数为发动机的 22 个参数, 设置 2 个隐藏层, 分别由 128 个、64 个神经元构成, 隐藏层的激活函数为 LeakyReLU, 输出参数为输入样本与模拟分布间的 EMD, 输出层不设置激活函数。此外, 在生成器和判别器的隐藏层设置 dropout 以防止过拟合, dropout 概率为 0.5。选择 Adam 优化器训练网络权重, 设置初始学习率为 0.0005, 截断常数为 0.01, 每训练 5 轮判别器后训练 1 轮生成器。

LeakyReLU 函数和 sigmoid 函数的计算方法分别为:

$$f(x) = \max(0, x) + \alpha \min(0, x) \quad (6)$$

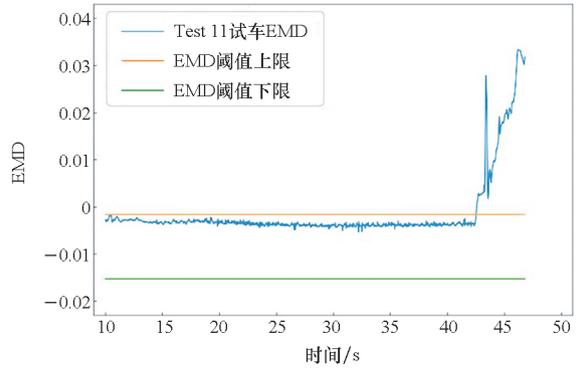
$$\sigma(x) = 1 / (1 + e^{-x}) \quad (7)$$

其中, α 是一个很小的常数, 通常设定为 0.01。这样, 神经网络在训练过程中就保留了一些小于 0 的输入值, 使得负值输入信息不会全部丢失。

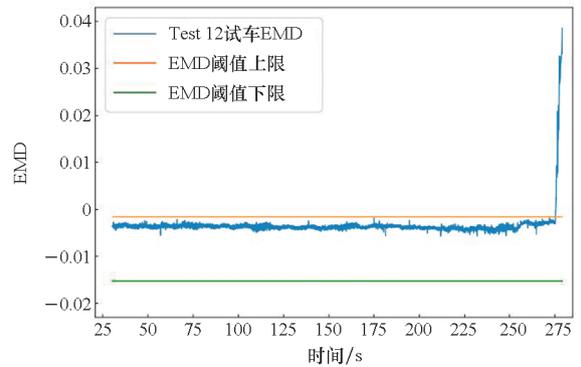
基于阈值的故障检测与诊断方法通常依据 3σ 原则划定故障阈值^[21-23], 即对于服从正态分布的参数, 其取值落在 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间的概率为 99.73%, 则依据区间 $(\mu - 3\sigma, \mu + 3\sigma)$ 判断样本是否发生异常的置信度为 99.73%。其中, μ 和 σ 分别为样本的均值和标准差。因此, 在这里划定稳态过程样本的 EMD 阈值为 $(\mu - 3\sigma, \mu + 3\sigma)$ 。

将训练集样本输入到训练好的判别器中, 输出 EMD, 依据 3σ 原则计算出故障阈值的上下限。将测试集样本输入判别器中, 得到测试样本的 EMD, 将其与 EMD 阈值进行比较, 得到故障检测结果。EMD 方法在测试集上未出现误报警, 在 4 次故障试车数据上的检测结果如图 6 所示。为了更清晰地显示检测结果, 令正常样本的检测结

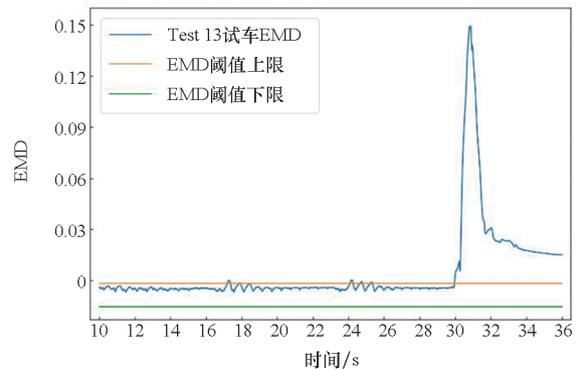
果为 1, 异常样本的检测结果为 -1, 如图 7 所示。从图 6 和图 7 中可以看出, EMD 方法可以有效检测出稳态故障。



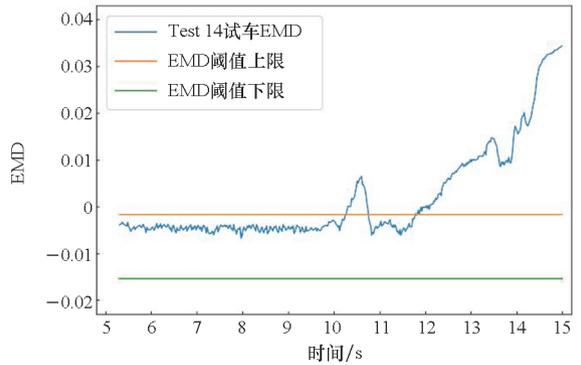
(a) Test 11



(b) Test 12



(c) Test 13



(d) Test 14

图6 各试车稳态过程故障检测结果

Fig.6 Detection results of steady-state process of each test

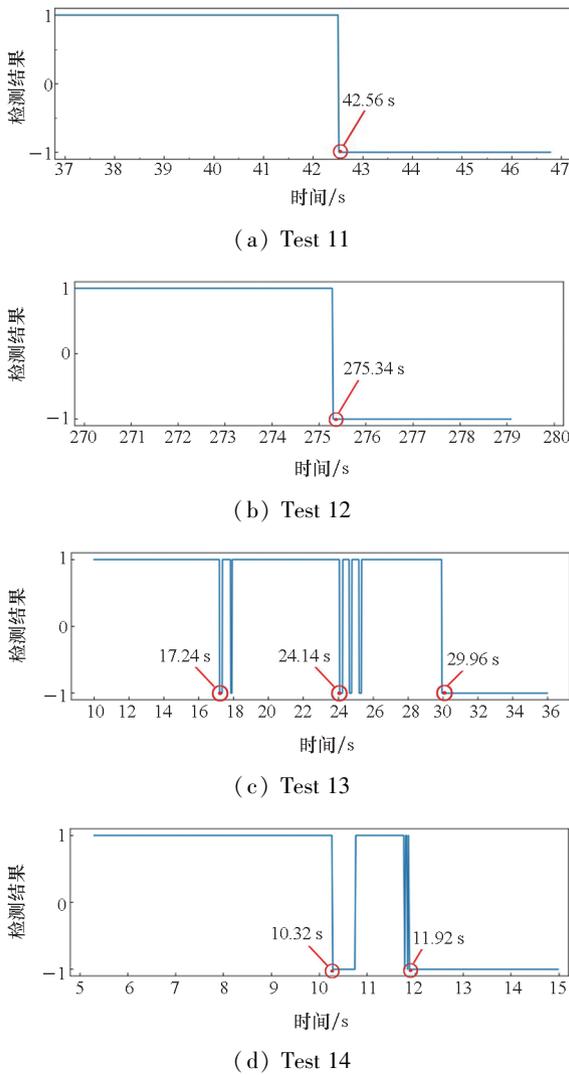


图 7 各试车稳态故障报警时间

Fig. 7 Alarming time of steady-state fault of each test

将 EMD 方法与红线关机系统 (red-line cutoff system, RCS)、自适应阈值算法 (adaptive threshold algorithm, ATA) 和 SVM 等方法的检测结果进行比较,如表 2 所示。可以看到,EMD 方法的及时性更好。

表 2 稳态故障检测结果对比

Tab. 2 Comparison of steady-state fault detection results
单位:s

试车编号	故障检测方法			
	EMD	RCS	ATA	SVM
Test 11	42.56	43.2	42.8	42.8
Test 12	275.34	275.8	275.5	275.8
Test 13	17.24	30.2	30.2	30.2
Test 14	10.32	13.0	12.3	12.3

值得注意的是,EMD 方法在 Test 13 试车的

17.24 s 就检测出故障并发出警报,并在 24 ~ 26 s 期间多次报警,直到 29.96 s 检测结果稳定为故障。Test 14 试车的检测结果在 10.32 s 第一次发出警报,在 10.76 s 恢复正常,直到 11.92 s 检测结果稳定为故障。为了对出现上述现象的原因进行解释,图 8 和图 9 分别显示了 Test 13 试车和 Test 14 试车氧化剂泵前阀门入口压力和温度的时间曲线(归一化值)。从图中可以看出,Test 13 试车的入口压力和入口温度在约 16 ~ 19 s、23 ~ 26 s 发生了剧烈波动,Test 14 试车的入口压力和入口温度在约 9.5 ~ 11.5 s 发生了剧烈波动。据此可以判断,LRE 在此期间很可能已经发生了异常,但各参数值仍在正常范围内,未能引起 RCS 等方法报警,证明 EMD 方法对 LRE 早期异常有更高的敏感性。

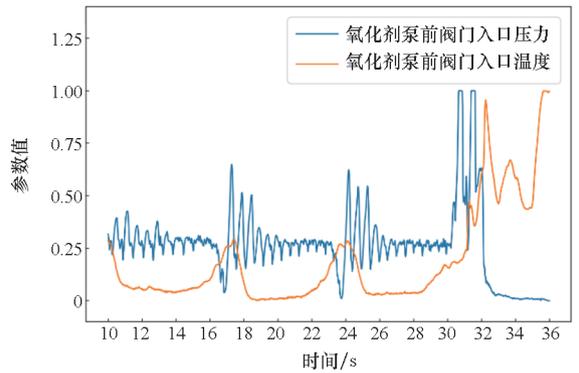


图 8 Test 13 试车部分参数的时间曲线

Fig. 8 Time curve of some parameters of Test 13

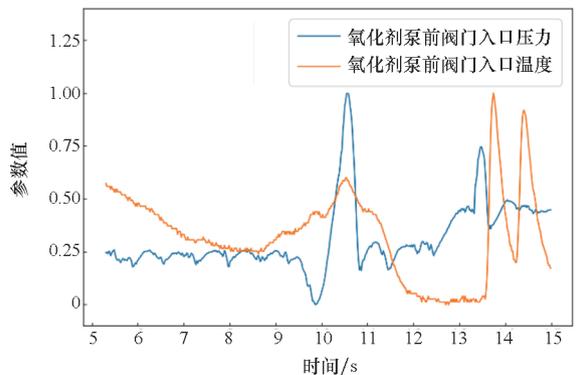


图 9 Test 14 试车部分参数的时间曲线

Fig. 9 Time curve of some parameters of Test 14

3.3 启动过程故障检测

截取 Test 01 ~ 07 试车的启动过程(约为 0 ~ 3 s)数据作为训练集训练 WGAN 模型。将训练集数据输入到训练好的判别器模型中,结果如图 10 所示,可以看到,训练集的 EMD 在时间上显示出较强的趋势性,且不同次试车数据在同一时刻的 EMD 显示出较强的一致性,因此应当对启动

过程每一时刻的 EMD 划定阈值。然而,由于启动过程的样本较少,其 EMD 不一定符合正态分布,故不能仅依据 3σ 原则划定阈值。

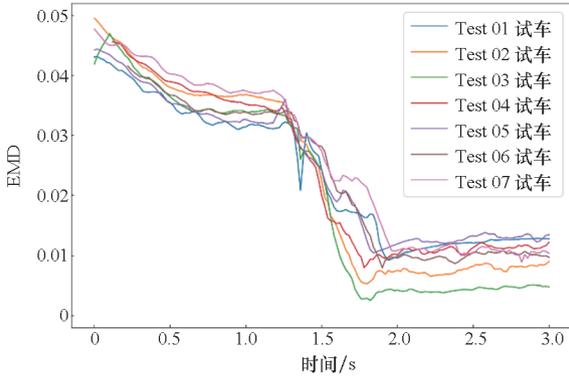


图 10 训练集启动过程的 EMD

Fig. 10 EMD of start-up transient of training set

为了探究启动过程 EMD 阈值的划定方案,对启动过程数据进行 k 折验证。令 $k=8$,即取 8 次正常试车中的 7 次试车数据为训练集,其余试车数据为测试集,在每次验证中划定 EMD 阈值为 3σ 、 4σ 、 5σ ,对测试集进行检测。所有情况下的 EMD 方法均未出现漏报警,误报警结果如表 3 所示。以实验 1 为例对表 3 进行说明,实验 1 即取 Test 02 ~ 08 试车数据为训练集训练 WGAN 模型,“ 3σ ”行中的“√”表示当 EMD 阈值为 3σ 时模型在 Test 01 试车数据上发生了误报警。从表中可以看到,当 EMD 阈值为 3σ 时的误报警率为 50%,当 EMD 阈值为 4σ 时的误报警率为 25%,当 EMD 阈值为 5σ 时的误报警率为 12.5%,这说明 EMD 阈值范围越大误报警率越低。

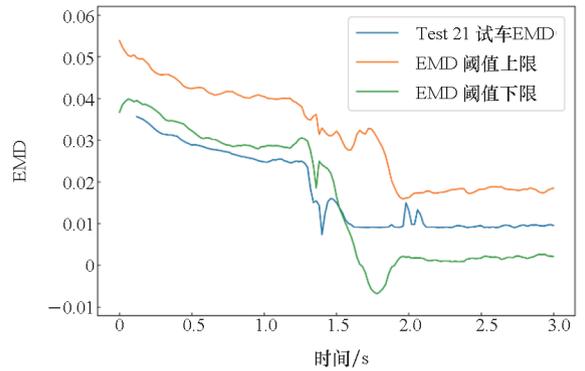
表 3 8 折验证下不同 EMD 阈值的误报警结果

Tab. 3 False alarming results with different EMD threshold in 8-fold validation

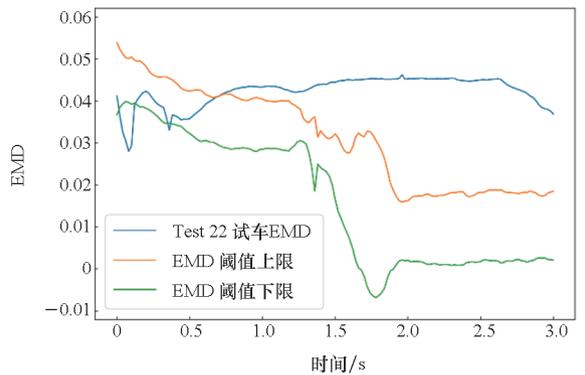
实验 代号	阈值			实验 代号	阈值		
	3σ	4σ	5σ		3σ	4σ	5σ
1	√	√	√	5			
2	√			6			
3				7	√	√	
4	√			8			

以实验 8 的结果为例对 EMD 方法的性能进行说明,EMD 阈值为 3σ 和 5σ 时实验 8 的检测结果如图 11 和图 12 所示。从图 11 中可以看到,EMD 阈值为 3σ 时,Test 21 试车的 EMD 从变化

趋势上看与正常数据的较为一致,但启动后 1.5 s 内的 EMD 超过了阈值,报警时间为 0.16 s。Test 22 试车的 EMD 从一开始就超过了阈值,报警时间为 0.06 s,虽然在 0.2 ~ 0.7 s 恢复正常,但其变化趋势与正常数据的偏差较大。从图 12 中可以看到,EMD 阈值为 5σ 时,由于阈值划定较宽,Test 21 试车的报警时间推迟到 0.22 s,在 0.3 ~ 1.5 s 间检测结果在正常与异常间多次反复。Test 22 试车的报警时间为 0.08 s。上述结果说明,在训练样本较少的情况下,当 EMD 阈值取 3σ 时 EMD 方法对启动过程的早期异常有较高敏感



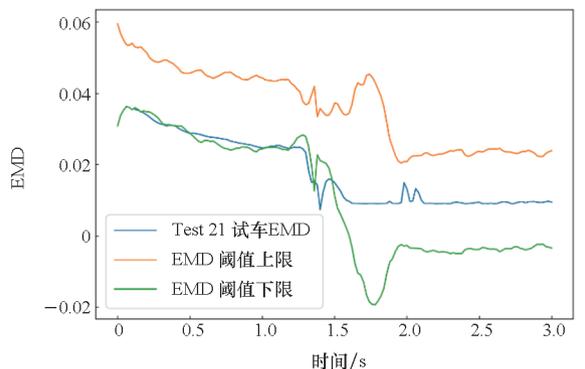
(a) Test 21



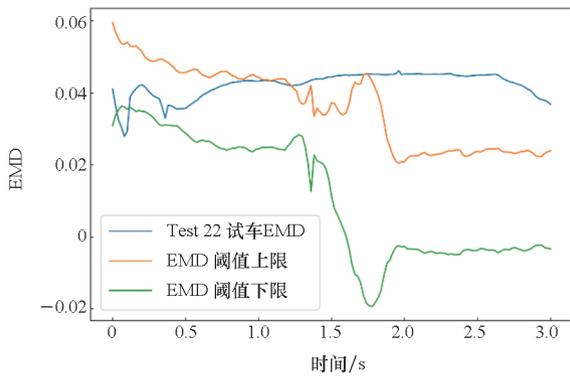
(b) Test 22

图 11 EMD 阈值为 3σ 时实验 8 检测结果

Fig. 11 Detection results of 8th experiment with EMD threshold of 3σ



(a) Test 21



(b) Test 22

图 12 EMD 阈值为 5σ 时实验 8 检测结果Fig. 12 Detection results of 8th experiment with EMD threshold of 5σ

性,当 EMD 阈值取 5σ 时仍可有效检测启动过程中的故障。

将 EMD 阈值为 5σ 时实验 8 的检测方法与 RCS、模糊聚类、CAE 等方法的检测结果进行比较,如表 4 所示。可以看到,EMD 方法在启动过程的报警时间远早于 RCS 等方法,进一步证明了 EMD 方法的及时性和对早期异常的敏感性。

表 4 启动故障检测结果对比

Tab. 4 Comparison of starting fault detection results

单位:s

故障检测方法	Test 21		Test 22	
	报警时间	提前时间	报警时间	提前时间
EMD	0.22		0.08	
RCS	20.00	19.78	1.32	1.24
模糊聚类	2.66	2.44	0.62	0.54
CAE	0.98	0.76	0.50	0.42

4 结论

本文提出了一种基于 Wasserstein 距离的液体火箭发动机故障检测方法,利用液氢液氧发动机地面热试车数据进行了验证。研究表明,在本文案例中,发动机稳态过程依据 3σ 原则划定 Wasserstein 距离故障阈值可以取得较好检测结果,对早期异常有较高敏感性且没有发生误报警;在训练样本较少的情况下,划定启动过程的 Wasserstein 距离故障阈值为 3σ 时方法的敏感性过高,产生了较高误报警率,划定阈值为 5σ 时方法仍可有效检测出故障,误报警率为 12.5%。此外,本文方法仅使

用正常数据训练 WGAN 模型,克服了训练故障数据不足的困难。

参考文献 (References)

- [1] 朱晓彬. 基于卷积神经网络的液体火箭发动机故障检测与诊断方法研究[D]. 长沙: 国防科技大学, 2020. ZHU X B. Research on fault detection and diagnosis methods of liquid-propellant rocket engine based on convolutional neural network [D]. Changsha: National University of Defense Technology, 2020. (in Chinese)
- [2] VENKATASUBRAMANIAN V, RENGASWAMY R, YIN K W, et al. A review of process fault detection and diagnosis: part I: quantitative model-based methods[J]. Computers & Chemical Engineering, 2003, 27(3): 293-311.
- [3] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques: part I: fault diagnosis with model-based and signal-based approaches[J]. IEEE Transactions on Industrial Electronics, 2015, 62(6): 3757-3767.
- [4] 董立宝, 何博, 聂万胜, 等. 基于 EnKF 算法的液体火箭发动机状态监测[J]. 战术导弹技术, 2022(3): 91-97. DONG L B, HE B, NIE W S, et al. Liquid rocket engine condition monitoring based on EnKF algorithm[J]. Tactical Missile Technology, 2022(3): 91-97. (in Chinese)
- [5] LEE K, CHA J, KO S, et al. Fault detection and diagnosis algorithms for an open-cycle liquid propellant rocket engine using the Kalman filter and fault factor methods[J]. Acta Astronautica, 2018, 150: 15-27.
- [6] CHA J, KO S, PARK S Y, et al. Fault detection and diagnosis algorithms for transient state of an open-cycle liquid rocket engine using nonlinear Kalman filter methods[J]. Acta Astronautica, 2019, 163: 147-156.
- [7] MARCOS A, PEÑÍN L F, MALIKOV D, et al. Fault detection and isolation for a rocket engine valve[J]. IFAC Proceedings Volumes, 2013, 46(19): 101-106.
- [8] KAWATSU K, TSUTSUMI S, HIRABAYASHI M, et al. Model-based fault diagnostics in an electromechanical actuator of reusable liquid rocket engine[C]//Proceedings of AIAA Scitech 2020 Forum, 2020.
- [9] CHA J, HA C, KO S, et al. Application of fault factor method to fault detection and diagnosis for space shuttle main engine[J]. Acta Astronautica, 2016, 126: 517-527.
- [10] HU L, HU N Q, ZHANG X P, et al. Novelty detection methods for online health monitoring and post data analysis of turbopumps [J]. Journal of Mechanical Science and Technology, 2013, 27(7): 1933-1942.
- [11] 刘英元, 陈海峰, 耿直, 等. 液体火箭发动机振动故障特征信号提取方法[J]. 火箭推进, 2019, 45(1): 77-82. LIU Y Y, CHEN H F, GENG Z, et al. Extraction method of characteristic signal for vibration fault of liquid rocket engine[J]. Journal of Rocket Propulsion, 2019, 45(1): 77-82. (in Chinese)
- [12] 刘岳鹏, 周磊, 金诚. 应力波技术的液体火箭发动机试验应用研究[J]. 低温工程, 2022(2): 59-64. LIU Y P, ZHOU L, JIN C. Research on application of liquid rocket engine test by stress waves technology[J]. Cryogenics, 2022(2): 59-64. (in Chinese)
- [13] BICKMORE T W, BICKFORD R L. Aerojet's Titan health assessment expert system [C]//Proceedings of 28th Joint

- Propulsion Conference and Exhibit, 1992.
- [14] 王冠,王婧雨,刘巧珍,等.数据驱动的运载火箭氧涡轮泵异常分析方法[J].宇航学报,2022,43(7):964-973.
WANG G, WANG J Y, LIU Q Z, et al. Data-driven anomaly analysis method of launch vehicle oxygen turbopump [J]. Journal of Astronautics, 2022, 43 (7): 964 - 973. (in Chinese)
- [15] 熊靖宇.液氧甲烷发动机故障特征分析与故障预测方法研究[D].长沙:国防科技大学,2018.
XIONG J Y. Investigation on fault feature analysis and fault prediction methods for LOX/methane rocket engines [D]. Changsha: National University of Defense Technology, 2018. (in Chinese)
- [16] 张振臻,陈晖,高玉闪.基于滑动时间窗主成分分析的液体火箭发动机传感器故障诊断方法[J].推进技术,2022,43(9):343-353.
ZHANG Z Z, CHEN H, GAO Y S. Sliding time windows principal component analysis based fault diagnosis method for liquid rocket engine sensors [J]. Journal of Propulsion Technology, 2022, 43(9): 343 - 353. (in Chinese)
- [17] 李宁宁,武小平,薛薇,等.基于遗传算法的大推力氢氧补燃发动机故障检测[J].计算机测量与控制,2022,30(8):14-18,43.
LI N N, WU X P, XUE W, et al. Fault diagnosis of high-thrust LOX/LH2 staged combustion cycle engines base on genetic algorithm [J]. Computer Measurement & Control, 2022, 30(8): 14 - 18, 43. (in Chinese)
- [18] DENG L Z, CHENG Y Q, SHI Y H. Fault detection and diagnosis for liquid rocket engines based on long short-term memory and generative adversarial networks[J]. Aerospace, 2022, 9(8): 399.
- [19] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672 - 2680.
- [20] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C]//Proceedings of the 34th International Conference on Machine Learning, 2017: 214 - 233.
- [21] 吴建军,黄强,程玉强,等.液体火箭发动机故障检测诊断理论与方法[M].北京:国防工业出版社,2013.
WU J J, HUANG Q, CHENG Y Q, et al. Theory and method of fault detection and diagnosis for liquid-propellant rocket engines [M]. Beijing: National Defense Industry Press, 2013. (in Chinese)
- [22] 黄敏超,邢宝玉.液体火箭发动机故障神经网络诊断[M].长沙:国防科技大学出版社,2015.
HUANG M C, XING B Y. Liquid rocket engine fault diagnosis based on neural network [M]. Changsha: National University of Defense Technology Press, 2015. (in Chinese)
- [23] DING S X. Data-driven design of fault diagnosis and fault-tolerant systems [M]. London: Springer, 2014.