

文章编号: 1671-7449(2024)05-0527-08

# 基于VMD和FCM的火箭发动机涡轮泵 状态监测方法

敖一峰<sup>1</sup>, 李洪<sup>2</sup>, 张金刚<sup>1\*</sup>, 黄辉<sup>1</sup>

(1. 北京宇航系统工程研究所, 北京 100076; 2. 中国航天科技集团有限公司, 北京 100048)

**摘要:** 面向重复使用火箭发动机的状态监测与故障诊断需求, 针对振动信号的非平稳性和难以提取有效故障特征的问题, 提出一种基于变分模态分解(Variational Mode Decomposition, VMD)和模糊C均值聚类(Fuzzy C-Means, FCM)的状态监测方法。采用优化VMD算法自适应地将振动信号分解为多个本征模态分量(Intrinsic Mode Function, IMF), 根据加权相关样本熵最大准则选取关键IMF分量; 利用t分布随机近邻嵌入(t-SNE)对关键IMF分量的多维时域、频域特征降维, 得到特征向量矩阵; 利用模糊C均值聚类算法实现发动机工作状态的监测。将该方法应用于发动机涡轮泵工作状态监测, 结果表明其能够提取振动信号关键特征, 准确识别涡轮泵工作状态, 测试集识别准确率达92.50%, 为火箭发动机状态监测与故障诊断提供了理论支撑。

**关键词:** 火箭发动机; 涡轮泵; 状态监测; 振动信号; 变模态分解; 模糊均值聚类

中图分类号: V434

文献标识码: A

doi: 10.3969/j.issn.1671-7449.2024066

**引用格式:** 敖一峰, 李洪, 张金刚, 等. 基于VMD和FCM的火箭发动机涡轮泵状态监测方法[J]. 测试技术学报, 2024, 38(5): 527-534.

AO Yifeng, LI Hong, ZHANG Jingang, et al. Rocket engine turbopump condition monitoring method based on VMD and FCM[J]. Journal of Test and Measurement Technology, 2024, 38(5): 527-534.

## Rocket Engine Turbopump Condition Monitoring Method Based on VMD and FCM

AO Yifeng<sup>1</sup>, LI Hong<sup>2</sup>, ZHANG Jingang<sup>1\*</sup>, HUANG Hui<sup>1</sup>

(1. Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China;

2. China Aerospace Science and Technology Corporation, Beijing 100048, China)

**Abstract:** Targeting the status monitoring and fault diagnosis requirements for reusable rocket engines, addressing the issues of non-stationary vibration signals and difficulty in extracting effective fault features, a method for state monitoring based on variational mode decomposition (VMD) and fuzzy C-means (FCM) clustering is proposed. The optimized VMD algorithm was adopted to adaptively decompose the vibration signal into multiple intrinsic mode functions (IMF), and key IMF components were selected based on the weighted correlation sample entropy maximum criterion; the time-domain and frequency-domain feature dimensionality reduction of key IMF components using t-distributed stochastic neighbor embedding (t-SNE) was employed to obtain the feature vector matrix, and the fuzzy center means clustering algorithm was used to monitor the

收稿日期: 2024-01-15

基金项目: 科技部国家重点研发计划(2021YFB3203300)

作者简介: 敖一峰(1998-), 男, 硕士生, 主要从事液体火箭发动机数据分析、故障诊断研究。E-mail: yifeng\_ao@163.com。

\* 通信作者: 张金刚(1984-), 男, 高级工程师, 主要从事测控通信技术研究。E-mail: zhangjg2009@126.com。

working status of the engine. The method was applied to the monitoring of the working status of the turbopump, and the results showed that it can extract key features of vibration signals and accurately identify the working status of the turbopump. The recognition accuracy of the test set reached 92.50%, providing theoretical support for status monitoring and fault diagnosis of rocket engines.

**Key words:** rocket engine; turbopump; condition monitoring; vibration signal; variational mode decomposition; fuzzy C-means

## 0 引言

随着大规模星座组网、载人探月工程及深空探测等重大工程的实施,为应对运载火箭的经济可行性和快速增长的进入空间需求,低成本、高可靠、快速响应的可重复使用运载火箭成为航天技术发展的重要方向<sup>[1-2]</sup>。

可重复使用运载火箭具有复杂的生命周期和使用剖面<sup>[3]</sup>,同时要具备智慧的特征<sup>[4]</sup>,因此,健康监控技术成为亟待解决的关键技术。作为运载火箭的关键核心系统,动力系统需要实现对关键部件工作状态的监测,具备故障诊断与健康监控能力,以提高任务执行能力及可靠性。在动力系统中,发动机故障多发会造成严重后果,因此,进行发动机状态监测与故障诊断是火箭飞行可靠性的重要保障,是任务重构和容错控制的前提与基础<sup>[5-6]</sup>。

液体火箭发动机状态监测的本质是对传感器测量数据进行特征提取与状态分类。20世纪70年代以来,美国为航天飞机主发动机(Space Shuttle Main Engine, SSME)研制了多种异常检测系统、健康监控系统<sup>[7-8]</sup>,以监测发动机运行状态和健康状况。发动机测量参数主要包含推力室室压、氧涡轮出口压力等缓变参数以及推力室、涡轮泵振动等速变参数<sup>[9]</sup>。

振动信号等速变参数作为发动机的关键测量数据,具有响应快速和敏感的特点,包含着深层次的、具有明确物理意义的信息。例如,涡轮泵振动信号包含转子工作频率的基频倍频分量,推力室振动信号能够表征中频共振和不稳定燃烧等信息。由波音公司联合MSFC研制的先进健康管理系系统(Advanced Health Management System, AHMS)开发了实时振动监控系统RTVMS<sup>[7]</sup>,能够通过振动信号监测SSME涡轮泵状态。夏鲁瑞<sup>[10]</sup>通过分析涡轮转子振动特征,选择振动信号频谱的工频、6倍频、12倍频幅值作为叶片断裂与脱落故障的特征,并通过变换域处理解决了转速波动导致特征频率变化的问题,实现了对叶片脱

落与断裂两种典型故障的诊断。Das等<sup>[11]</sup>通过对比涡轮泵典型故障振动信号的短时傅里叶变换频谱,识别出区分故障激发的载波谐振频率,并采用希尔伯特变换解调得到一阶谐波进行故障检测。Aiswarya<sup>[12]</sup>提出一种基于快速傅里叶变换和时域特征的涡轮泵故障诊断方法,提取涡轮泵振动信号的平均值、峭度因子等时域指标作为故障特征,并采用支持向量机实现了故障检测。

面向重复使用运载火箭状态监测与故障诊断的需求,本文基于箭上测量的振动信号,提出一种变分模态分解(Variational Mode Decomposition, VMD)和模糊C均值聚类(Fuzzy-C-Mean, FCM)相结合的状态监测方法,依据能量比和加权相关样本熵分别设置VMD分解层数和选取关键IMF分量,从而使得模型能解决人为选择特征及从复杂特征中筛选关键特征的问题。利用振动传感器在发动机不同状态下采集到的振动信号,通过VMD算法对振动信号进行分解并选取关键IMF分量,结合时域、频域特征提取关键IMF分量特征,采用FCM得到聚类中心并依据最大贴度实现状态分类与监测。基于飞行试验测得的涡轮泵轴向振动信号,将该方法应用于发动机涡轮泵状态监测,测试集识别准确率达到92.50%。

## 1 基于VMD-FCM的状态监测方法

### 1.1 VMD算法优化

VMD分解是一种自适应的、完全非递归的模态变分和信号处理方法,能够根据信号自身频谱分布将信号分解为 $K$ 个中心频率为 $\omega_k$ 的模态函数,同时各模态的估计带宽之和最小<sup>[13]</sup>。VMD改善了传统经验模态分解(Empirical Mode Decomposition, EMD)及集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)的递归筛选求解过程,能有效抑制端点效应和模态混叠,对噪声鲁棒性更强,适用于处理箭上非平稳、非线性振动信号。本质上,VMD将分解问题表示为带约束模型的求解问

题,其约束变分表达式可表示为<sup>[14]</sup>

$$\begin{cases} \min_{\mu_k, \omega_k} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot \mu_k(t) e^{i\omega_k t} \right] \right\|_2^2 \right\}, \\ s.t. \sum_k \mu_k(t) = x(t), \end{cases} \quad (1)$$

式中:  $\partial_t$  为函数对时间的偏导数;  $\delta(t)$  为单位脉冲函数。

通过引入二次惩罚因子和增广拉格朗日函数将约束变分问题转化为非约束变分问题,得到

$$L(\{\mu_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-i\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_k \mu_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k \mu_k(t) \right\rangle, \quad (2)$$

式中:  $\alpha$  为二次惩罚因子,保证高斯噪声环境下信号重构的准确性;  $\lambda(t)$  为拉格朗日乘子,用于保证约束条件的严格性。

利用交替方向乘子法连续更新各分量及其中心频率,最终得到迭代更新过程如下式(3)和式(4)。

$$\hat{\mu}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{\mu}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\omega \omega |\hat{\mu}_k(\omega)|^2 d\omega}{\int_0^\omega |\hat{\mu}_k(\omega)|^2 d\omega}. \quad (4)$$

### 1.1.1 确定分解层数

VMD 算法能够实现对信号的自适应分解,但需提前设置分解层数  $K$ ,  $K$  值过大会导致模态裂解和产生虚假模态,  $K$  值过小会导致模态混叠和遗漏有效模态。

本文以能量比  $r$  为约束选取  $K$  值,能量比  $r$  定义为残差信号与原信号能量的比值,由于发动机工作环境恶劣,测量参数受噪声干扰严重,本文能量比阈值选择为 0.3。能量比表达式为

$$r = \frac{E_0 - E_r}{E_0} = \frac{\sum x(t)^2 - \sum u_k(t)^2}{\sum x(t)^2}. \quad (5)$$

### 1.1.2 选取关键模态分量

原信号经过 VMD 分解得到的部分 IMF 分量受噪声干扰严重,不能反映原信号包含的信息,因此需要选取关键的 IMF 分量。由于单一的指标难以反映振动信号的特性,因此,本文融合皮尔逊相关系数  $\rho$  和样本熵(Sample Entropy, SampEn)提出了加

权相关样本熵指标(Weighted Correlation Sample Entropy, WCSE)来选取关键 IMF 分量。

加权相关样本熵的计算如下

$$\rho_i(x_i, x) = \frac{E[(x_i - \bar{x}_i)(x - \bar{x})]}{\sigma(x_i)\sigma(x)}, \quad (6)$$

$$SE_i = \ln B^m(p) - \ln A^m(p), \quad (7)$$

$$WCSE_i = \rho_i / SE_i, \quad (8)$$

式中:  $\rho_i$ ,  $SE_i$  分别为第  $i$  个 IMF 分量的皮尔逊相关系数和样本熵;  $m$ ,  $p$  分别为样本熵计算的维数和相似容限阈值;  $E(\bullet)$  为期望因子。

相关系数反映 IMF 分量与原信号的关联性,相关系数越大,与原信号关联性越强;样本熵是一种时间序列复杂性测度方法<sup>[15]</sup>,熵值越小,时间序列越规则,熵值越大,时间序列越复杂。因此,加权相关样本熵越大,IMF 分量幅值越大,序列受噪声影响越小,有效性越强。

## 1.2 特征选择与降维

### 1.2.1 特征选择

状态监测的目的在于区分不同状态的特征,本文选择表 1 中 6 个时域、频域特征以表征 IMF 分量。其中,均方根、裕度和峭度 3 个时域特征分别反映信号的变化规律、稳定性和非重复性瞬态脉冲成分<sup>[16]</sup>,频率重心、频谱均值和频谱均方根值 3 个频域特征分别反映信号主频率位置变化、频谱能量和功率谱的收敛性<sup>[17]</sup>。

表 1 时域、频域特征

Tab. 1 Time domain and frequency domain characteristics

序号	特征	表达式
1	均方根	$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
2	裕度	$CL_f = X_p / \left[ \frac{1}{N} \sum_{i=1}^N \sqrt{ x_i } \right]^2$
3	峭度	$K_v = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{x_{var}^2}$
4	频率重心	$f_c = \frac{\sum_{k=1}^K f_k \cdot p(f)}{\sum_{k=1}^K p(f)}$
5	频谱均值	$\bar{P} = \frac{1}{K} \sum_{k=1}^K p(f)$
6	频谱均方根值	$P_r = \frac{1}{K-1} \sum_{k=1}^K (p(f) - \bar{P})^2$

其中,  $x_p$  为信号的峰值;  $\bar{x}$  为信号的均值;  $x_{var}$  为信号的方差;  $p(f)$  为信号频谱。

提取筛选的各关键 IMF 分量的 6 个时域、频域特征, 构建混合特征向量为

$$S = [\varphi_{11}, \varphi_{12}, \dots, \varphi_{16}, \dots, \varphi_{31}, \dots, \varphi_{m,n}], \quad (9)$$

式中:  $\varphi_{m,n}$  为信号经过优化 VMD 分解后第  $m$  个关键 IMF 分量的第  $n$  个时域、频域特征。

### 1.2.2 特征降维

t 分布随机近邻嵌入(t-SNE)是一种无监督非线性的流体学习算法, 能够有效实现高维数据降维, 并保留数据间的局部特性。其基本思想是分别采用高斯分布和柯西分布将高维空间和低维空间样本间距离转换为概率分布, 并通过最小化两个分布间的 KL 散度得到低维结果。算法基本步骤可参考文献[18]。

利用 t-SNE 将 12 维的混合特征向量降成 3 维向量  $S_{\text{new}}$ , 作为聚类算法输入。

$$[S_{\text{new}} = [tsne_1, tsne_2, tsne_3]]. \quad (10)$$

### 1.3 模糊均值聚类算法

FCM 是一种无监督的聚类算法, 本质是利用隶属度函数来描述样本对各个类别的归属程度<sup>[19]</sup>, 适用于处理无标签的箭上传感器测量数据。

FCM 将  $n$  个样本  $x = \{x_1, x_2, \dots, x_n\}$  分为  $c$  个模糊子集  $A = \{\bar{A}_1, \bar{A}_2, \dots, \bar{A}_c\}$ , 定义隶属度函数  $\mu_{ik}$  来表示样本  $x_i$  相对于模糊集合  $\bar{A}_k$  的隶属度,  $\mu_{ik}$  需要满足

$$\left\{ \begin{array}{l} \mu_{ik} | \mu_{ik} \in [0, 1]; \sum_{k=1}^c \mu_{ik} = 1, \forall i; 0 < \sum_{i=1}^n \mu_{ik} < n, \forall k \end{array} \right\}. \quad (11)$$

FCM 的目标函数  $J_b$  表示为

$$J_b(U, V) = \sum_{i=1}^n \sum_{k=1}^c \mu_{ik}^m (d_{ik})^2, \quad (12)$$

式中:  $U, V$  分别为隶属度函数矩阵和聚类中心矩阵;  $d_{ik} = d(x_i - v_k) = \|x_i - v_k\|$  为样本  $x_i$  到聚类中心  $v_k$  的欧氏距离;  $m$  为加权指数, 取值范围为  $1 \leq m \leq \infty$ 。

FCM 算法通过不断迭代聚类中心  $V$  和隶属度矩阵  $U$  进行求解<sup>[20]</sup>, 得到最终解。

### 1.4 优化 VMD-FCM 算法流程

基于 VMD 和 FCM 的状态监测方法流程如图 1 所示, 主要包括特征提取、状态监测和效果评估三部分。

详细步骤如下所示:

1) 首先对振动信号进行预处理, 去除野点数据并进行归一化处理, 以滑动窗口和局部覆盖策略对样本进行分割和数据量增强;

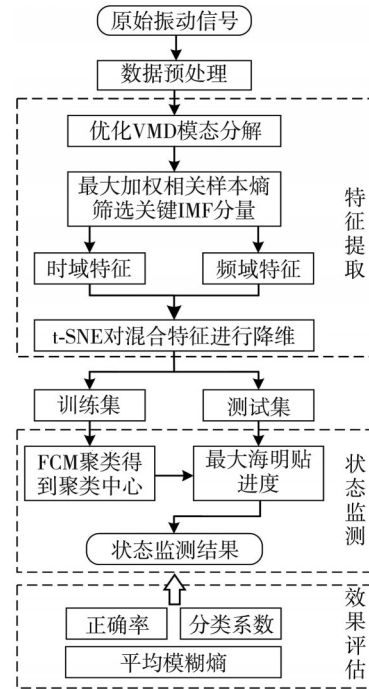


图 1 VMD-FCM 状态监测流程

Fig. 1 VMD-FCM condition monitoring process

2) 利用 VMD 对振动信号样本进行自适应分解, 得到  $K$  个 IMF 分量, 根据能量比确定 VMD 分解层数  $K$ ;

3) 根据式(8)计算各 IMF 分量的加权相关样本熵, 选取熵值大的 IMF 作为关键分量;

4) 针对选取的各关键 IMF 分量, 提取均方根、裕度、峭度、频率重心、频谱均值、频谱均方根 6 个时域、频域特征, 构建混合特征;

5) 利用 t-SNE 将混合特征降维成 3 维特征向量, 形成训练集和测试集, 作为状态监测的输入;

6) 训练集送入 FCM 算法中进行训练, 得到聚类中心, 然后依据海明贴进度对测试集进行状态监测, 最终得到分类结果。

## 2 火箭涡轮泵实例分析

为验证本文方法的有效性, 以火箭发动机涡轮泵为识别对象, 使用某型号液体火箭发动机的飞行遥测数据进行验证。

### 2.1 试验数据

该型火箭发动机涡轮泵工作在强振动环境

中,振动来源于转子旋转的径向力、涡轮叶片上的气动力、流体脉动和其他振源的多路振动。此涡轮泵离心轮的结构为 6 个长叶片、12 个中叶片和 6 个短叶片,振动信号由安装在泵壳体的轴向振动传感器测得,采样频率为 6 kHz。

发动机通过氧副系统的两台燃气阀对发动机的混合比进行阶跃式调节,依据氧流量的大小,发动机将处于高工况、中工况、低工况 3 种工作状态。假设飞行过程中氧涡轮泵发生堵塞故障,导致氧涡轮泵做功能力降低,振动信号表现为幅值降低、频率逐渐下降,发动机工况调节及故障过程见图 2。因此,根据涡轮泵工作状态,可将振动数据划分为 4 种状态:高工况、中工况、低工况和氧泵故障状态。




图 2 工况调节及故障过程


Fig. 2 Condition regulation and fault process

### 2.2 数据预处理


数据预处理包括野点去除、数据归一化和样本分割。首先去除野点数据并归一化处理,然后采用滑动窗口对数据进行样本分割,截取信号长度为  $N=2\ 048$ ,利用局部覆盖的扩展策略增强数据量,设置样本间  $1/2N$  重叠。

最终得到 3 种工况数据各 120 组,故障数据 40 组,选取 80% 为训练样本、20% 为测试样本。

随机选取一组中工况下氧泵振动数据进行频谱分析,归一化后的时域、频域波形如图 3 所示。



(a) 时域波形



(b) 频域波形

图 3 中工况时域、频域波形

Fig. 3 Time domain and frequency domain waveform of medium operating conditions

分析可得,氧泵轴向振动信号频谱包含 4 个典型的频率成分,  $f_1$  (310 Hz) 为涡轮转子工作频率,  $f_2$  (1 549 Hz)、 $f_3$  (1 860 Hz) 和  $f_4$  (2 167 Hz) 处频谱峰值分别为涡轮泵的 5 倍频、6 倍频和 7 倍频。

### 2.3 特征提取

采用 VMD 算法对预处理后的振动信号进行模态分解,设置二次惩罚因子  $\alpha=2\ 000$ ,能量比阈值  $r=0.3$ ,分解层数  $K$  的优化区间为  $[2, \infty)$ 。计算不同  $K$  值下 VMD 分解的能量比如图 4 所示。




图 4 不同 K 值下的能量比

Fig. 4 Energy ratios under different K values

可以看出,当  $K \geq 5$  时,4 种状态能量比均小于 0.3,认为分解已经充分,因此设置 VMD 分解层数为 5。

以中工况为例,随机选取一组数据, VMD 分解得到的 IMF 分量波形及其频谱如图 5 所示。




图 5 VMD 分解结果及其对应频谱

Fig. 5 VMD decomposition results and spectrum

由图 5 可知, VMD 能够将涡轮泵轴向振动信号中的不同频率分量分离,图 5 反映了各频率成分的时域和频域幅值的相对大小。IMF1 分量频谱主要分布在 200~400 Hz,存在明显的谐波成分,反映了涡轮转子的工作频率; IMF2 分量的频谱中心为 798 Hz; IMF3~IMF5 分别为涡轮泵工

作频率的5倍频、6倍频和7倍频,其中6倍频相对幅值最大,且存在明显谐波成分。

随机选取4种状态各10组样本,得到VMD分解的IMF分量,依据式(6)、式(7)计算相关系数和样本熵,选取样本熵维数 $m=2$ ,相似容限阈值 $\rho=0.2SD(x)$ ( $SD$ 为序列标准差),得到10组加权相关样本熵WCSE的平均值如表2所示。可以看出,IMF1(基频)和IMF4(6倍频)的熵值最大,因此,选取IMF1、IMF4分量作为关键分量,分别提取表1中的6个时域、频域特征,构成长度为12的混合特征向量 $S \in R^{1 \times 12}$ 。

然后利用t-SNE算法将高维特征向量降维至3维特征向量 $S_{\text{new}} \in R^{1 \times 3}$ ,最终得到320组训练样

本和80组测试样本。

表2 各IMF分量的加权相关样本熵值

Tab. 2 Weighted correlation sample entropy of each IMFs

信号类型	加权相关样本熵				
	IMF1	IMF2	IMF3	IMF4	IMF5
高工况	0.503	0.386	0.403	<b>3.146</b>	<b>0.682</b>
中工况	<b>1.225</b>	0.693	0.839	<b>2.289</b>	1.020
低工况	<b>1.538</b>	0.802	0.857	<b>1.773</b>	1.358
氧泵故障	<b>2.124</b>	0.620	0.812	<b>2.679</b>	1.460

为进一步展示本文所提方法特征提取效果,将t-SNE降维特征与原始特征、PCA降维特征进行比较,其中原始特征选择IMF4分量的3个时域特征、PCA降维特征选取前3个主元,结果如图6所示。




图6 不同特征对比结果

Fig. 6 Comparison results of different features

由图6可以看出,原始特征、PCA降维特征的高工况和故障两种状态的样本分散、类内间距较大,与故障状态振动信号逐渐变化的特点相符,中工况和低工况两种状态的样本混叠严重;t-SNE降维特征不同样本分类清晰,除了中工况和低工况部分样本混叠外,其他状态的样本聚类效果良好,证明了本文方法在特征提取中的有效性和优越性。

## 2.4 状态监测

采用FCM算法对训练集进行聚类识别,设置聚类数目为4,加权指数 $m=2$ ,判别精度 $\epsilon=1 \times 10^{-7}$ ,最大迭代次数为 $g_{\text{max}}=1000$ ,得到4种状态的分类结果及聚类中心见图7及式(13)。

$$C = \begin{bmatrix} 0.81 & 0.27 & -0.23 & -0.82 \\ -0.69 & 0.44 & 0.68 & -0.34 \\ -0.80 & -0.34 & 0.20 & 0.14 \end{bmatrix}^T. \quad (13)$$

由图7可以看出,FCM取得了良好的聚类中心,高工况和故障数据被完全分离,中工况和低工况数据存在部分混叠,训练集识别准确率达到93.96%。

以聚类中心作为测试样本分类的依据,矩阵 $C$ 的4列分别为高工况、中工况、低工况和故障状态的聚类中心。根据择近原则对测试集样本进行

状态分类,求取待测试样本与聚类中心的贴适度。本文采用海明贴适度进行计算,见式(14)。

$$N(A, B) = 1 - \frac{1}{n} |A(x_k) - B(x_k)|, \quad (14)$$

式中: $A, B$ 分别为标准模式和待识别对象。




图7 FCM分类结果

Fig. 7 FCM classification results

贴适度越大,说明样本模型与标准模型越相似。针对测试集,分别计算每个样本与聚类中心的贴适度,将最大贴适度作为样本类别,得到混淆矩阵如图8所示。分析可得,测试集的平均识别准确率达到92.50%。高工况和故障状态的识别率为100%,没有出现错分情况;中工况和低工况状态的部分样本被相互错分,其原因是中工

况与低工况转换过程中开关阀门存在过渡过程, 使得两种工况的部分振动信号类似。




图 8 测试集混淆矩阵

Fig. 8 Test set confusion matrix

### 2.5 方法对比

为验证本文所提方法的优越性, 设置两组对比实验: ① 提取原始振动信号的均值、峰值、绝对平均值、均方值、方根、方差、波形因子、峰态因子、脉冲因子、裕度、偏度和峭度共 12 个时域特征, 同样构建长度为 12 的特征向量, 再采用 t-SNE 降维并归一化后送入 FCM 算法中; ② 采用 EEMD 分解将振动信号分解为 5 个 IMF 分量, 通过计算各 IMF 的加权相关样本熵, 同样得到熵值最大的两个分量为 IMF1(基频)和 IMF4(6 倍频), 分别提取 2 个分量的 6 个时域、频域特征, 构建长度为 12 的特征向量, 再采用 t-SNE 降维并归一化后送入 FCM 算法中。

两个对比实验训练集的分类结果如图 9 所示。可以看出, 时域特征方法得到的中工况和低工况的特征混叠严重, 难以区分; 采用 EEMD 提取到的特征较为分散, 其原因是 EEMD 提取到的 IMF 分量中噪声成分较多, 影响聚类效果。

表 3 不同特征的分类结果比较

Tab. 3 Classification results for different characteristics

特征类型	各状态分类正确率 %				平均正确率 %	分类系数	平均模糊熵
	高工况	中工况	低工况	油泵故障			
时域特征 + t-SNE	100.00	87.50	79.17	100.00	90.00	0.78	0.32
EEMD + t-SNE	95.83	83.33	75.00	100.00	86.25	0.67	0.48
VMD + t-SNE	100.00	91.67	83.33	100.00	92.50	0.86	0.25

根据图 6、图 7、图 9 和表 3 分析可得, 利用 VMD 方法提取关键 IMF 分量, 将关键分量的时域、频域混合特征通过 t-SNE 提取的低维特征用于涡轮泵工作状态监测, 可以显著提高识别率, 测试集识别准确率达到了 92.50%, 分类系数最高、平均模糊熵最低, 分类效果最好。

## 3 结论

本文通过开展 VMD 和 FCM 算法在发动机健

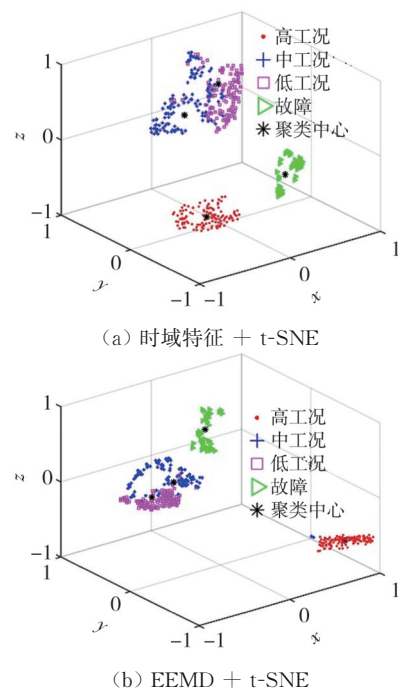


图 9 不同方法的分类结果

Fig. 9 Classification results of different methods

针对两个对比实验, 同样利用训练集得到聚类中心, 然后采用最大海明贴进度对测试集样本进行分类。针对本文 3 种方法提取的特征分类结果, 采用正确率、分类系数  $F$  和平均模糊熵  $G$  3 个评价指标进行评价, 结果如表 3 所示。分类系数和平均模糊熵分别为隶属度  $\mu_{ik}$  的均方值和信息熵大小,  $F$  越接近 1、 $G$  越接近 0, 聚类效果越好。

$$F = \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^c \mu_{ik}^2, \quad (15)$$

$$G = -\frac{1}{n} \sum_{i=1}^n \sum_{k=1}^c \mu_{ik} \ln \mu_{ik} \circ \quad (16)$$

康监控方面的研究工作得到以下结论:

1) 针对箭上振动信号非平稳、非线性的特点, VMD 算法能够将信号自适应分解为表征不同特征的 IMF 分量, 有效地提取出非平稳信号内的特征信息。

2) 通过加权相关样本熵作为关键模态评估指标, 能够反映模态分量与原始信号的相关性和序列复杂度, 有效解决了 VMD 算法的最佳模态选择问题。

3) 相比于传统时域特征和 EEMD 方法, 本文所提方法能够有效提取反映涡轮泵工作状态的特

征,具有更高的分类准确率,达到了92.50%,为解决火箭发动机健康监测提供了新思路。

### 参考文献:

- [1] 包为民,汪小卫,董晓琳. 航班化航天运输系统对动力的发展需求与技术挑战[J]. 火箭推进, 2021, 47(4): 1-5.  
BAO Weimin, WANG Xiaowei, DONG Xiaolin. Development demands and challenges of propulsion technology for space transportation system in airline-flight-mode[J]. Journal of Rocket Propulsion, 2021, 47(4): 1-5. (in Chinese)
- [2] ZHONG Y, LIU D, WANG C. Research progress of key technologies for typical reusable launcher vehicles [C]//IOP Conference Series: Materials Science and Engineering, 2018, 449: 012008.
- [3] 包为民. 可重复使用运载火箭技术发展综述[J]. 航空学报, 2023, 44(23): 8-33.  
BAO Weimin. A review of reusable launch vehicle technology development [J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(23): 8-33. (in Chinese)
- [4] 李洪. 智慧火箭发展路线思考[J]. 宇航总体技术, 2017, 1(1): 1-7.  
LI Hong. The developing roadmap of intelligent launch vehicle[J]. Astronautical Systems Engineering Technology, 2017, 1(1): 1-7. (in Chinese)
- [5] 张智, 马英, 朱海洋, 等. 运载火箭可重构性及评价方法研究[J]. 宇航学报, 2023, 44(9): 1305-1316.  
ZHANG Zhi, MA Ying, ZHU Haiyang, et al. Research on the concept and evaluation method for reconfigurability of launch vehicles [J]. Journal of Astronautics, 2023, 44(9): 1305-1316. (in Chinese)
- [6] 魏远明, 朱海洋, 马英, 等. 新一代中型运载火箭故障诊断与容错重构总体方案研究[J]. 导弹与航天运载技术(中英文), 2023(2): 11-15.  
WEI Yuanming, ZHU Haiyang, MA Ying, et al. Research on fault detection and reconstruction of new generation medium launch vehicle [J]. Missiles and Space Vehicles, 2023(2): 11-15. (in Chinese)
- [7] HAWMAN M W, GALINAITIS W S, TULPUL S, et al. Framework for a space shuttle main engine health monitoring system[R]. NASACR-185224, 1990.
- [8] FIORUCCI T R, LAKIN D R, REYNOLDS T D. Advanced engine health management applications of the SSME real-time vibration monitoring system[EB/OL]. <https://doi.org/10.2514/6.20003622>.
- [9] 王姝淇, 刘梓琰, 王冠, 等. 火箭发动机涡轮泵故障检测及预测算法研究[J]. 宇航总体技术, 2023, 7(3): 44-54.  
WANG Shuqi, LIU Ziyang, WANG Guan, et al. Research of fault detection and prediction algorithm for rocket engine turbopump [J]. Astronautical Systems Engineering Technology, 2023, 7(3): 44-54. (in Chinese)
- [10] 夏鲁瑞, 胡芑庆, 秦国军. 转速波动状态下涡轮泵典型故障诊断方法[J]. 推进技术, 2009, 30(3): 342-346.  
XIA Lurui, HU Niaoqing, QIN Guojun. Diagnosis method for turbopump typical fault under conditions of speed fluctuation [J]. Journal of Propulsion technology, 2009, 30(3): 342-346. (in Chinese)
- [11] DAS D, PADMANABHAN P, KUMARESAN V, et al. Case study on bearing fault diagnosis in liquid rocket engine using envelope detection technique[C]// International Conference on Energy, Materials Sciences & Mechanical Engineering. Singapore: Springer, 2022: 357-366.
- [12] AISWARYA N, SUJA PRIYADHARSINI S, MONI K S. An efficient approach for the diagnosis of faults in turbo pump of liquid rocket engine by employing FFT and time-domain features [J]. Australian Journal of Mechanical Engineering, 2018, 16(3): 163-172.
- [13] 郭文静, 曹慧亮. 基于变分模态分解和神经网络算法的微机械陀螺温度补偿[J]. 测试技术学报, 2021, 35(6): 495-502.  
GUO Wenjing, CAO Huiliang. Temperature compensation of MEMS gyroscope based on variational mode decomposition and neural network algorithm[J]. Journal of Test and Measurement Technology, 2021, 35(6): 495-502. (in Chinese)
- [14] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [15] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy[J]. American Journal of Physiology-Heart and Circulatory Physiology, 2000, 278(6): H2039-H2049.
- [16] 谢光军. 液体火箭发动机涡轮泵实时故障检测技术及系统研究[D]. 长沙: 国防科学技术大学, 2006.
- [17] LEI Y, HE Z, ZI Y, et al. Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs[J]. Mechanical Systems and Signal Processing, 2007, 21(5): 2280-2294.