

基于 MVMD 和瞬时相位的液压管路故障特征提取方法

宋旭,魏勤*,鲁玲,陈珊,周昊辰

(武汉理工大学 信息工程学院, 武汉 430070)

摘要: 为了对液压管路中的故障进行程度和类型的识别与定位,提出多元变分模态分解(MVMD)和瞬时相位特征与主频幅值加权融合的方法,采用分布式光纤布喇格光栅(FBG)监测管路应变,从传感器信号的相位和幅值中提取有效故障特征,并进行了仿真实验。仿真结果表明:根据加权融合特征向量可以有效地对管路故障特征进行识别和定位,故障程度识别正确率达 98% 以上。

关键词: 液压管路;分布式光纤布喇格光栅;相位特征;多元变分模态分解

中图分类号:TN256 文献标志码:A 文章编号:1002-5561(2021)10-0034-06

DOI: 10.13921/j.cnki.issn1002-5561.2021.10.008

开放科学(资源服务)标识码(OSID):



Fault feature extraction method of hydraulic pipeline based on MVMD and instantaneous phase

SONG Xu, WEI Qin*, LU Ling, CHEN Shan, ZHOU Haocheng

(School of Information Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract: In order to identify and locate the degree and type of fault in hydraulic pipeline, a method of multivariate variational mode decomposition (MVMD) and weighted fusion of instantaneous phase characteristics and dominant frequency amplitude is proposed. The pipeline strain is monitored by distributed fiber Bragg grating (FBG), and the effective fault characteristics are extracted from the phase and amplitude of sensor signals, and the simulation experiments are carried out. The simulation results show that the pipeline fault features can be identified and located effectively according to the weighted fusion feature vector, and the accuracy of fault degree recognition is more than 98%.

Key words: hydraulic pipeline; distributed fiber Bragg grating; phase feature; multivariate variational mode decomposition

0 引言

液压管路作为运输各种液体的媒介,广泛应用于航空航天、船舶动力等机械工程领域中。管路系统长期工作在高压、强振动的环境中,极易发生故障^[1],导致严重的安全事故。其中,卡箍松动和裂纹是液压管路的 2 种常见故障。通过传感器监测液压管路的运行状态,并研究有效的故障特征提取方法是液压管路系统的安全保障。

目前,关于液压管路的故障机理已有大量的理论

研究,而故障的识别与定位技术仍是液压管路故障诊断中的重点和难题,其中有效的故障特征提取方法更是研究的重中之重。在复杂的内、外部激励环境下,传感器信号具有非平稳性和非线性特点,传统的故障诊断方法往往难以发挥作用。现有的研究成果大都集中于时域、频域和时频域^[2],对信号的相位特征的研究较少。已有研究表明:信号相位也包含故障特征,并且对故障更敏感,因此将相位特征引入至液压管路的故障识别中具有重要的意义。而瞬时相位反映了信号相位随时间的变化,是一个全新的时间序列,在此基础上研究故障特征提取方法是一个很好的选择^[3]。

本文提出基于多元变分模态分解(MVMD)和瞬时相位的液压管路故障特征提取方法,该方法利用 MVMD 在处理非平稳信号上的优势,将瞬时相位特征与基于主频幅值的特征进行融合,有效地解决液压管路工作环境下故障特征难以提取和识别的问题。

收稿日期:2020-12-24。

作者简介: 宋旭(1997—),男,硕士研究生,现就读于武汉理工大学信息工程学院信息与通信工程专业,主要研究方向是光纤传感、信号处理及光纤 F-P 传感器光谱信号的解调。曾荣获“兆易创新杯”第十五届中国研究生电子设计竞赛华中赛区一等奖。

* **通信作者:** 魏勤(1980—),女,博士,副教授,研究方向为信号处理。



1 基于 MVMD 和瞬时相位的故障特征提取方法

基于 MVMD 和瞬时相位的故障特征提取方法主要分为 2 个步骤:第一步是采用 MVMD 进行故障信号的分解;第二步是提取信号的瞬时相位自相关散点图(ASIP)散度特征和主频幅值特征,并将两者融合,作为特征向量输入分类器进行分类。

1.1 MVMD 算法原理

MVMD 是一种信号分解算法,由 REHMAN N 等人^[4]在 2019 年首次提出,通过建立约束变分模型表达式,将信号以非递归的方式自适应地分解。MVMD 将多个信号在相同的频率尺度分解为相同数量的固有模态函数(IMF)之和,每一个 IMF 都是一个调频调幅信号。它把传统的变分模态分解(VMD)^[5]算法从一维扩展到多维,为处理多变量或多通道数据提供了极大的便利,同时保证多通道分解时分量频率的一致性。MVMD 获取 IMF 分量的方法是基于输入数据的所有通道之间存在的共同频率分量,在信号的分解过程引入了变分模型,构造求变分模型最优解方程。在这个过程中,各通道的 IMF 分量同时迭代更新其中心频率和带宽,从而自适应地得到 k 个窄带 IMF 分量。MVMD 算法中需要提前设定 2 个重要的参数,分别是 IMF 分量个数 k 和惩罚因子 α 。将液压管路中 N 个通道的布喇格光纤光栅(FBG)应变信号 $x(t)$ 记为 $[x_1(t), x_2(t), \dots, x_N(t)]$, t 表示时间。使用 MVMD 算法分解信号的具体步骤如下:

①假设有 k 个多通道 IMF 分量信号 $u_k(t)$,使:

$$x(t) = \sum_{i=1}^k u_k(t) \quad (1)$$

其中, $u_k(t) = [u_1(t), u_2(t), \dots, u_N(t)]$, $i=1, 2, \dots, k$ 。

②对每一个 IMF 分量进行 Hilbert 变换,分别得到向量 $u_k^+(t)$,并将单边频谱与指数项 $e^{-j\omega_k t}$ 相乘,使每个模态的频谱被调制到与它相应的基频带上。通过谐波转换后,经 $u_k^+(t)$ 的梯度函数的 L_2 范数平方估计出各模态 $u_k^+(t)$ 的带宽。受约束的相关优化问题变为:

$$\min_{\{u_{k,n}\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \sum_{n=1}^N \left\| \delta_t [u_{k,n}^+(t) e^{-j\omega_k t}] \right\|_2^2 \right\} \quad (2)$$

$$\text{s.t. } X_N(t) = \sum_{k=1}^K u_{k,n}(t), n=1, 2, \dots, N \quad (3)$$

其中, $u_{k,n}^+(t)$ 为通道为 n 、模式为 k 的解析信号, ω_k 为中心频率, δ_t 表示与时间相关的偏导数, $\| \cdot \|_2^2$ 表示 L_2 范数的平方。

③求解上述变分方程,构造增广的拉格朗日乘子为:

$$L(\{u_{k,n}\}, \{\omega_k\}, \lambda_n) = \alpha \sum_{k=1}^K \sum_{n=1}^N \left\| \delta_t u_{k,n}^+(t) e^{-j\omega_k t} \right\|_2^2 + \sum_{n=1}^N \left\| x_n(t) - \sum_{k=1}^K u_{k,n}(t) \right\|_2^2 + \sum_{n=1}^N \left\langle \lambda_n(t), x_n(t) - \sum_{k=1}^K u_{k,n}(t) \right\rangle \quad (4)$$

其中, λ_n 为拉格朗日乘子, $\langle \cdot \rangle$ 表示内积。

④为了解决转变后的非约束性的变分问题,本文应用乘子交替方向法进行交替更新,然后求取 $u_k(t)$ 和中心频率便得到分解后的信号分量,模式更新为:

$$\hat{u}_{k,n}^{l+1}(\omega) = \frac{\hat{x}_n(\omega) - \sum_{i=1}^{k-1} \hat{u}_i^{l+1}(\omega) - \sum_{i=k+1}^K \hat{u}_{i,n}^l(\omega) + \frac{\hat{\lambda}^l(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^l)^2} \quad (5)$$

其中, $\hat{x}_n(\omega)$ 、 $\hat{\lambda}^l(\omega)$ 、 $\hat{u}_{i,n}(\omega)$ 和 $\hat{u}_k^{l+1}(\omega)$ 表示傅里叶变换后的信号, l 表示迭代次数。中心频率更新为:

$$\omega_k^{l+1} = \frac{\int_0^\alpha \omega \left| \hat{u}_k^{l+1}(\omega) \right|^2 d\omega}{\int_0^\alpha \left| \hat{u}_k^{l+1}(\omega) \right|^2 d\omega} \quad (6)$$

通过更新关系自适应地分解信号的频带,得到 k 个窄带 IMF 分量。这样,多元信号每个通道的信号分解得到的 IMF 数目相等,且同一层上的多元 IMF 具有相同的频率尺度,适用于多元非平稳信号的分析。

1.2 瞬时相位的故障特征提取方法

Hilbert 变换^[7]可用于计算复杂信号的瞬时参数,它将一个一维的信号变成二维复平面上的信号,通过实部、虚部、模和幅角,反应信号的瞬时参数。对一个长度为 N 的离散时域信号 $s(t)$,计算其瞬时相位的步骤为:

①对信号 $s(t)$ 进行 Hilbert 变换,即 $s(t)$ 与 $\frac{1}{\pi t}$ 卷积,如式(7)所示。

$$H[s(t)] = s(t) \times \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{s(\tau)}{t-\tau} d\tau \quad (7)$$

其中, τ 表示卷积积分变量。

②构建复信号 $z(t)$:

$$z(t) = s(t) + jH[s(t)] \quad (8)$$

③计算信号的瞬时相位:

$$\theta(t) = \arctan \left\{ \frac{H[s(t)]}{s(t)} \right\} \quad (9)$$

进一步地,以当前时刻和下一时刻的瞬时相位值

构造坐标 $[\theta(t_n), \theta(t_{n+1})]$, 其中 $n=1, 2, \dots, N-1$ 。当原始信号长度为 N 时, 则可生成 $N-1$ 个二维向量坐标, 并以散点图的形式在直角坐标系中绘制 (称为 ASIP), 直观地表示瞬时相位的规律性。在直角坐标系中, 一个理想的正弦波 ASIP 将呈现一种聚集的、线性的趋势, 当信号中存在噪声或者信号成分变得复杂时, 相应的 ASIP 会在该范围内分散分布。为了定量地描述这种变化, 本文定义了一个新的特征值——ASIP 散度, 记作 D 。计算过程如下:

①对 ASIP 进行线性拟合, 得到一条拟合直线为:

$$\theta_{fit}(t_{n+1}) = k \times \theta(t_n) + b \quad (10)$$

其中, k 、 b 分别为拟合直线的斜率和截距。

②计算 ASIP 中每个点到拟合直线的距离并求和, 得到 ASIP 散度 D 为:

$$D = \sum_{n=1}^{N-1} \frac{|k \times \theta(t_n) - \theta(t_{n+1}) + b|}{\sqrt{k^2 + 1}} \quad (11)$$

ASIP 散度是一种基于统计的特征计算方法, 可以描述信号的规律程度, 信号越简单、ASIP 分布越集中, 相应的 ASIP 散度越小; 反之, 信号越复杂, ASIP 散度越大。为研究信号成分变化对 ASIP 散度的影响, 本文对其影响因素进行仿真分析, 设计仿真信号如下:

$$\begin{cases} s_1(t) = \cos(2\pi \times 10t) \\ s_2(t) = \cos(2\pi \times 40t) \\ s_3(t) = s_1(t) + s_2(t) \\ s_4(t) = s_1(t) + n_1 \\ s_5(t) = s_2(t) + n_2 \end{cases} \quad (12)$$

其中, n_1 和 n_2 表示高斯白噪声, 且 s_4 和 s_5 的信噪比分别为 10 dB 和 5 dB。信号采样频率均为 1000 Hz, 序列长度为 1 s, 仿真信号的瞬时相位波形如图 1 所示。可以看出, 各信号的瞬时相位取值范围固定。对比 s_1 、 s_2 、




图 1 仿真信号瞬时相位

s_3 的瞬时相位波形可知, 当信号频率成分单一时, 瞬时相位只会反映信号频率的变化, 而不受信号幅值大小的影响; 由 s_4 和 s_5 的瞬时相位波形可知, 当信号中的频率成分变得复杂时, 瞬时相位波形会出现畸变, 并且若这种变化是随机的、无规律的, 瞬时相位波形的畸变也是杂乱的。仿真信号 ASIP 如图 2 所示, 可以看出, s_4 和 s_5 的 ASIP 散点在拟合直线周围分散分布, 表明 ASIP 对信号成分的变化很敏感, 尤其是随机性的变化。相比于图 1, ASIP 更能直观地、清晰地反映出信号频率成分的变化, 尤其是随机噪声对信号的影响。




图 2 仿真信号 ASIP

进一步地, 计算各信号

表 1 仿真信号 ASIP 散度

ASIP 散度, 结果如表 1 所示。

仿真信号	ASIP 散度
s_1	44.4
s_2	177.7
s_3	208.9
s_4	507.7
s_5	922.5

对比信号 s_1 、 s_2 可知, 信号的频率越大, 其 ASIP 散度越大; 当信号中存在多个频率成分时, 其 ASIP 散度会大于信号成分中最大频率的 ASIP

散度; 当信号中存在随机成分 (如 s_4 和 s_5) 时, 其 ASIP 散度会大幅增加。

由以上分析可知, ASIP 散度可以有效反映信号频率成分的变化, 是一项信号规律性衡量指标。当液压管路在固定频率下振动时, 响应信号也有相同的频率, 而故障通常会导致响应信号幅值和频率成分发生变化^[8], 因此可以将本文所提出的基于瞬时相位的特征提取方法用于液压管路实验的信号处理中。

1.3 主频幅值故障特征提取方法

由于 ASIP 散度特征只能反映信号频率成分的变化, 不能反映其幅值的大小, 因此引入幅值特征。当管路出现故障时, 参照工作应变模态的概念^[9], 其应变信号的主频幅值将发生变化, 可构建主频幅值特征向

量。本文通过 MVMD 后的信号计算每个通道中每个分量与对应的原始 FBG 应变信号序列的能量比值,作为该分量的权值,组成每个分量频率尺度下的权值向量为:

$$W_j = [w_{1j}, w_{2j}, \dots, w_{ij}, \dots, w_{qj}]^T \quad (13)$$

能量权值计算公式为:

$$w_{ij} = \frac{E(h_{ij})}{E(FBG_j)} = \frac{\sum_{k=1}^L [h_{ij}(k)]^2}{\sum_{k=1}^L [FBG_j(k)]^2} \quad (14)$$

其中, $E(h_{ij})$ 表示分解后各个信号分量的能量, $E(FBG_j)$ 表示原始某一通道 FBG 信号的能量, L 表示 FBG 序列长度, j 表示第 j 个 FBG 信号, i 表示第 j 个 FBG 信号的第 i 个分量。

假设原始 N 元 FBG 信号经 MVMD 后, 每个通道均得到 q 个 IMF 分量, 进而得到 N 元 FBG 信号的权值矩阵 $w(q \times N)$ 为:

$$w(q \times N) = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1j} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2j} & \dots & w_{2N} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{i1} & w_{i2} & \dots & w_{ij} & \dots & w_{iN} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{q1} & w_{q2} & \dots & w_{qj} & \dots & w_{qN} \end{bmatrix} \quad (15)$$

再计算多元 FBG 信号的每一层 IMF 的权值和:

$$S_i = \sum_{j=1}^N w_{ij}, i=1, 2, \dots, q \quad (16)$$

由于激励频率固定, 液压管路应变信号的主频率也固定, 因此原始信号经 MVMD 后, 主频率所对应的 IMF 分量权值一定是最大的。假设当 $i=i'$ 时, $S_{i'} = \max\{S_i\}$, 则此时该通道中该分量所对应的信号 $h_{i'} = [h_{i'1}, h_{i'2}, \dots, h_{i'N}]$, 即为此通道的主 IMF 分量, 然后计算信号 $h_{i'j}(j=1, 2, \dots, N)$ 的频谱峰值 P_{w_j} , 组成主频幅值特征向量 $P_w = [P_{w1}, P_{w2}, \dots, P_{wN}]$ 。

1.4 瞬时相位和主频幅值特征融合

传统的多特征融合方式有 2 种: add (相加) 和 concat (级联)^[10]。add 是作特征值的叠加, 不改变特征向量的维数, 其方式是信息之间的叠加, 在维度不变的情况下使描述管路故障特征的每一通道下的信息量增多, 更有利于分类器对故障特征识别; 而 concat 是直接拼接多个特征, 增加了特征向量的维数, 其方式是通道数的合并, 也就是描述管路故障的特征向量维度增加, 而每一维度特征下的信息量不变。在管路故障特征提取中, 使用 add 方式进行故障特征融合, 可以极大地减小计算量。

充分考虑信号的瞬时相位对频率成分变化的敏感性和信号的主频幅值对幅值变化的敏感性, 本文将 ASIP 散度特征向量和主频幅值特征向量进行特征融合, 增强故障程度之间的差异性, 实现准确的故障定位。由于 ASIP 散度与应变主频幅值有不同量级的取值范围, 因此首先需要分别对二者进行归一化处理。对于一个 N 维的分布式 FBG 应变信号, 特征融合具体步骤具体步骤如下:

①计算原始信号经 MVMD 后在每个频率尺度下 IMF 的 ASIP 散度 $D_{ij}, i=1, 2, \dots, q$, 得到 N 元 FBG 信号的 ASIP 散度矩阵 $D(q \times N)$ 为:

$$D(q \times N) = \begin{bmatrix} D_{11} & D_{12} & \dots & D_{1j} & \dots & D_{1N} \\ D_{21} & D_{22} & \dots & D_{2j} & \dots & D_{2N} \\ \vdots & \vdots & & \vdots & & \vdots \\ D_{i1} & D_{i2} & \dots & D_{ij} & \dots & D_{iN} \\ \vdots & \vdots & & \vdots & & \vdots \\ D_{q1} & D_{q2} & \dots & D_{qj} & \dots & D_{qN} \end{bmatrix} \quad (17)$$

基于 MVMD 的加权 ASIP 散度 D_{w_j} 计算公式为:

$$D_{w_j} = \sum_{i=1}^q D_{ij} \times w_{ij}, j=1, 2, \dots, N \quad (18)$$

其中, $D_w = [D_{w1}, D_{w2}, \dots, D_{wN}]$ 为分布式 FBG 应变信号的加权 ASIP 散度特征向量。

②将加权 ASIP 散度特征向量归一化在 $[0, 1]$ 区间, 得到新的特征向量 $D' = [D'_{11}, D'_{12}, D'_{13}, \dots, D'_{1N}]$, 其中 $D'_i = \frac{D_{wi} - \min(D)}{\max(D) - \min(D)}, i=1, 2, \dots, N$ 。

③计算每个 FBG 信号的幅频谱, 并求其主频峰值, 组成 $1 \times N$ 的特征向量 $P = [P_1, P_2, P_3, \dots, P_N]$; 同样, 根据步骤②将其归一化在 $[0, 1]$ 区间, 得到新的特征向量 $P' = [P'_1, P'_2, P'_3, \dots, P'_N]$ 。

④令 D' 和 P' 相加, 即得到基于 MVMD 和瞬时相位的分布式 FBG 信号加权融合后的特征向量: $DP_w = [DP_{w1}, DP_{w2}, \dots, DP_{wN}] = [D'_{11} + P'_1, D'_{12} + P'_2, \dots, D'_{1N} + P'_N]$ 。

根据上述步骤, 将 ASIP 散度特征向量和主频幅值特征向量进行融合后得到各程度下卡箍松动故障和裂纹故障的融合特征分布情况。最后, 根据分布特征直方图中与故障位置对应的 FBG 传感器的故障程度出现的规律(递增或递减), 判断该 FBG 传感器附近是否存在故障。

2 实验与结果分析

2.1 实验内容

本文搭建的液压管路实验台实物图如图 3 所示。



图3 液压管路实验台实物图

该管路通过2个卡箍固定于2个金属支座上,每个卡箍由2个螺钉固定,管路上安装有9个FBG应变传感器(从左至右依次编号为FBG1,FBG2,FBG3, ..., FBG9)。实验采用353ND环氧树脂胶将FBG沿管路径向粘贴于管表面,用于测量管路在振动过程中管表面的应变响应。由于液压管路各部件之间存在振动,油液与管路之间也存在流固耦合振动,导致液压管路长期工作在强振动的环境中,故采用激振器模拟液压管路振动信号,激振器上的金属杆通过AB胶垂直固定在管路上,激励参数通过函数信号发生器设定,经功率放大器放大后传送到激振器。激振器与功率放大器的型号分别为KSI-758ST与KSI-758PA1500,实验中设定激振器的频率为70 Hz;FBG信号通过光纤光栅解调仪(GDS-4K-4)采集,采样频率为2000 Hz。通过FBG应变信号的时域波形可以反映管路的振动状态^[10]。

实验模拟液压管路故障情况,以卡箍和裂纹作为研究对象。在振动环境下,管路的卡箍松动和裂纹会出现摩擦和间隙这2种典型的非线性现象^[2],从而产生非线性、非平稳的故障信号;根据FBG应变信号反映管路的振动情况,从FBG应变信号中提取管路的故障特征。实验通过卡箍拧紧力的大小和裂纹的深度分别模拟卡箍的松动程度和裂纹故障程度,实验中这2种工况的参数如表2所示。

2.2 实验结果

以健康状态为例,先采集液压管路的分布式FBG应变信号,然后对信号进行MVMD,设置IMF分量个数 k 为4,惩罚因子 α 为4000。经MVMD后,9个FBG信号均被分解得到4阶IMF分量信号,每一个IMF中都包含了与管路状态相关的信息,按式(5)计算得到的权值矩阵如式(19)所示。

式(19)中,每一列代表一个FBG的4个IMF分量,其中各IMF中的权值最大的均为IMF2,权值之和最大的也是第2层IMF,即IMF2为主IMF分量。计算得到归一化后的主频幅值特征向量和ASIP散度特征向量,相加后得到液压管路健康状态下的ASIP散度与主频幅值加权融合特征向量如式(20)所示。

按照上述方法,分别计算各种工况下(不同程度松动、裂纹)的加权融合特征向量 DP_w ,得到卡箍松动故障和裂纹故障下的特征分布直方图如图4所示。


由图4(a)可以看出,当卡箍1松动时,其左右两侧的应变感知均会受到影响,相应地表现在FBG1、FBG2、FBG3和FBG4处的加权融合特征值上,且随松动程度的增加变化更明显,松动程度4下的变化最明显;而相对应的卡箍2,其左右两侧感受应变的FBG7、FBG8、FBG9无明显变化,由此可判断出现松动故障的是卡箍1而非卡箍2。从图4(b)可知,当FBG2和FBG3中间存在裂纹时,与健康状态相比,加权融合特征的变化主要体现在裂纹发生地的两侧,而远离裂纹的FBG4~FBG9基本无变化;在裂纹程度1和程度2下,加权融合特征直方图变化最大的地方为FBG1和FBG3处,因此可判断裂纹发生在FBG1和FBG3之间;随着裂纹程度加深,FBG2处开始逐渐减小,而FBG1和FBG3的特征的变化表现为接近健康状态的趋势,由此可确定裂纹在FBG2附近。因此,可以根据特征直方图各点变化的位置对应的FBG序号确定管

$$w(4 \times 9) = \begin{bmatrix} 0.01585 & 0.00193 & 0.01556 & 0.00205 & 0.00173 & 0.00237 & 0.02070 & 0.00231 & 0.01680 \\ 0.27469 & 0.98064 & 0.27024 & 0.98202 & 0.98719 & 0.96536 & 0.15280 & 0.95968 & 0.32701 \\ 0.05451 & 0.00069 & 0.06404 & 0.00097 & 0.00013 & 0.00286 & 0.06803 & 0.00186 & 0.08498 \\ 0.04901 & 0.00066 & 0.05007 & 0.00042 & 0.00013 & 0.00147 & 0.06299 & 0.00253 & 0.04492 \end{bmatrix} \quad (19)$$


$$DP_w = [0.63218 \quad 1.01089 \quad 0.58026 \quad 0.72622 \quad 0.99605 \quad 0.57219 \quad 0.65005 \quad 0.84206 \quad 1] \quad (20)$$

表2 工况参数列表

工况	健康状态	松动程度1	松动程度2	松动程度3	松动程度4	工况	健康状态	裂纹程度1	裂纹程度2	裂纹程度3	裂纹程度4	裂纹程度5
卡箍拧紧力/mm	4.8	2.4	1.2	0.6	0.3	裂纹深度/mm	0	0.5	1.0	2.0	3.0	4.0



(a) 卡箍松动故障



(b) 裂纹故障

图4 各工况下的加权融合特征向量分布直方图

路上故障的位置,并且随着故障程度的增加变化趋势更明显。

本文将提取到的特征向量输入到支持向量机(SVM)中进行液压管路故障识别。在数据处理中均以1 s为一个数据样本长度,即除健康状态外,每种工况下均有30个数据样本与特征提取相对应。随机选取2/3的特征样本作为训练集,剩余样本作为测试样本集,将提取得到的分布式FBG加权融合特征向量输入SVM中分别进行卡箍松动和裂纹故障的程度识别,重复50次,平均识别准确率都达到98%以上。

为进一步评价本文所提出的基于MVMD和瞬时相位的液压管路故障识别方法的性能,将提取得到的特征向量对故障的识别效果与文献[13]中的基于MEMD和MSE的特征提取方法效果进行比较,并采用相同的样本选择方式和SVM分类器,结果如表3所示。可以看出,本文的方法对于故障类型和故障程度的识别准确率均高于MEMD+MSE的特征提取方法,并且故障程度识别准确率可达98%以上。

表3 不同方法对液压管路故障识别准确率比较

方法	故障类型	卡箍松动	裂纹程度
	识别准确率	程度识别准确率	识别准确率
MVMD+ASIP	78.84%	98.68%	99.02%
MEMD+MSE	71.68%	68.46%	79.25%

3 结束语

本文针对液压管路的卡箍松动及裂纹故障问题,研究分析了一种新的管路故障特征提取方法,采用MVMD的信号分解方法处理FBG的非平稳信号后,提取ASIP散度特征和主频幅值特征,并经过加权融合,可以准确地对故障进行检测与定位;此外,与基于MEMD+MSE的故障检测方法相比,本文提出的基于MVMD和瞬时相位的故障检测方法检测准确率高。

参考文献:

- [1] 黄加荣. 复杂振动环境下飞机典型液压管路的动力响应研究 [D]. 西安: 西安电子科技大学, 2019.
- [2] LI Z, GAO P, ZHAO D, et al. Fault diagnosis and location of the aero-engine hydraulic pipeline based on Kalman filter [J]. Advances in Mechanical Engineering, 2017, 9(12): 1-9.
- [3] LU L, WEI Q, XIAO N, et al. A new feature extraction method based on instantaneous phase for clamp looseness on pipes [C]//2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference, May 25-27, 2018, Xi'an, China. New York: IEEE, 2018: 1306-1310.
- [4] REHMAN N, HANIA A. Multivariate variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2019, 67(23): 6039-6052.
- [5] KONSTANTIN D, DRAGOMIRETSKIY Z. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [6] 张琛, 赵荣珍, 邓林峰. 基于变分模态分解奇异值熵的滚动轴承微弱故障辨识方法 [J]. 振动与冲击, 2018, 37(21): 87-91.
- [7] 胡志祥, 任伟新. 基于递归希尔伯特变换的振动信号解调和瞬时频率计算方法 [J]. 振动与冲击, 2016, 35(7): 39-43.
- [8] 高攀, 张小龙, 何育民, 等. 含横向裂纹管道固有频率的变化规律研究 [J]. 机械科学与技术, 2015, 34(1): 60-64.
- [9] 谭跃刚, 余兆祥, 曲永志, 等. 基于应变模态的液压卡箍松动识别与定位 [J]. 液压与气动, 2017(7): 96-102.
- [10] 李春茂, 张凯兵, 刘薇, 等. 基于典型相关分析特征融合的行人再识别方法 [J]. 光电子·激光, 2020, 31(5): 500-508.
- [11] LI Z, GAO P, ZHAO D, et al. Fault diagnosis and location of the aero-engine hydraulic pipeline based on Kalman filter [J]. Advances in Mechanical Engineering, 2017, 9(12): 1-9.
- [12] 蔡林. 基于光纤光栅传感的液压管理裂纹检测研究 [D]. 武汉: 武汉理工大学, 2018.
- [13] LIU Q, CHEN Y F, FAN S Z, et al. EEG artifacts reduction by multivariate empirical mode decomposition and multiscale entropy for monitoring depth of anaesthesia during surgery [J]. Medical & Biological Engineering & Computing, 2016, 55(8): 1-16.