

基于光纤布拉格光栅传感的齿轮故障检测方法

陈勇^{1*}, 陈亚武¹, 刘志强¹, 刘焕淋²

¹重庆邮电大学工业物联网与网络化教育部重点实验室, 重庆 400065;

²重庆邮电大学光纤通信重点实验室, 重庆 400065

摘要 针对齿轮故障难以识别的问题,提出了一种用于齿轮异常状态识别的自适应噪声补偿聚合经验模态分解方法。利用光纤布拉格光栅(FBG)传感器提取齿轮的振动信号,通过自适应补偿高斯白噪声使振动信号频谱均匀化,以消除经验模态算法分解产生的模态混叠现象。利用相关系数和峭度值组成综合评价指标来选择有效分量,并提取其特征,采用支持向量机对齿轮故障进行识别与分类。实验结果表明:所提方法能有效地识别齿轮的不同状态(正常、轻度磨损、重度磨损、点蚀、裂纹以及断齿等),识别正确率均在 90%以上。

关键词 光纤光学; 齿轮; 故障检测; 光纤布拉格光栅; 经验模态分解; 模态混叠

中图分类号 TN253; TN911.7

文献标志码 A

doi: 10.3788/CJL202047.0304007

A Gear Fault Detection Method Based on a Fiber Bragg Grating Sensor

Chen Yong^{1*}, Chen Yawu¹, Liu Zhiqiang¹, Liu Huanlin²

¹Key Laboratory of Industrial Internet of Things & Network Control, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

²Key Laboratory of Optical Fiber Communication Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract In this study, we propose a gear fault identification method based on adaptive-noise complementary ensemble empirical mode decomposition to solve the problem associated with the identification of gear faults. Initially, we used a fiber Bragg grating to extract the gear vibration signals, and uniformized the spectrum of vibration signal by adaptively adding Gaussian white noise to eliminate the mode mixing caused by the empirical modal algorithm. Subsequently, we used the correlation coefficient and the kurtosis value to obtain comprehensive evaluation indexes for selecting the effective components and extracting the features of the effective components. Finally, we used a support vector machine to identify the gear faults. The experimental results denote that the proposed method can be used to effectively identify the states of gears, including normal, mild-wear, severe-wear, pitting, cracks, broken teeth. Furthermore, the gear state identification accuracy is more than 90%.

Key words fiber optics; gear; fault detection; fiber Bragg grating; empirical mode decomposition; mode mixing

OCIS codes 060.3735; 070.2025; 070.1060

1 引言

齿轮作为机械设备中重要的传动装置,在制造业中起着重要作用,其运行状态直接影响整个设备的工况^[1]。齿轮的工作环境恶劣,内部结构复杂,很容易出现磨损、裂纹和断齿等故障,导致加工精度降低,甚至出现重大事故,造成经济损失或人员伤亡,因此对齿轮进行故障检测至关重要^[2]。

分析振动信号中的故障频率分量可以实现齿轮故障诊断。傅里叶变换能对信号进行时频转换^[3],但复杂的频谱分量会导致获取的故障信息不准确。文献[4]利用多尺度滤波重构算法来处理齿轮的振动信号,进而有效检测出齿轮的故障,但无法对故障类型进行识别;文献[5]提出了一种基于特征频率能量比的行星齿轮故障诊断方法,但它能识别的故障类型较少,且未考虑识别准确率的问题。上述方法

收稿日期: 2019-09-16; 修回日期: 2019-10-14; 录用日期: 2019-10-28

基金项目: 国家自然科学基金(51977021)

* E-mail: chen Yong@cqupt.edu.cn

只是对信号进行全局分析,尚未提取信号的局部特征,因此检测精度不理想。齿轮振动信号是一种非平稳、非线性信号。经验模态分解(EMD)算法能很好地处理非平稳信号,可以将信号分解成一系列本征模态函数(IMF),每个 IMF 分量都能表征不同的频率成分^[6]。文献[7]利用 EMD 算法处理振动信号,检测出了齿轮的局部故障,但经 EMD 分解后会出现模态混叠问题,使 IMF 分量无法表征正确的物理信息;文献[8]提出了一种 EEMD 算法,通过加入高斯白噪声的方法来减轻混叠效应,理论上通过总体平均能消除 IMF 分量中的白噪声,但实际上各分量中还会有少量残余噪声;文献[9]提出了 CEEMD 算法,该算法通过加入极性相反的高斯白噪声消除了 IMF 分量中的残余噪声,但若加入白噪声的功率选择得不合理,同样也会产生模态混叠现象。

针对上述问题,本文提出了一种自适应噪声补偿聚合经验模态分解算法。该算法利用光纤布拉格光栅(FBG)传感器提取齿轮的振动信号,通过自适应补偿的高斯白噪声使振动信号频谱均匀化,以此来消除 EMD 算法分解产生的模态混叠现象。同时,本文还提出了一种确定 IMF 有效分量的途径,并利用支持向量机对故障进行了识别与分类。最后通过实验验证了所提方法的有效性。

2 齿轮故障的识别方法

齿轮的振动信号通常由安装在齿轮箱表面的加速度传感器来采集,这种电学传感器很容易受到外界电磁干扰的影响,导致测量精度下降,且不易实现全方位检测^[10]。近年来出现的 FBG 传感器具有体积小、灵敏度高、抗电磁干扰以及易复用等优点^[11],已被广泛应用于周界安防、冲击定位等领域^[12]。根据上述优点,FBG 传感器能满足测量齿轮振动信号的要求。

2.1 振动信号的采集

FBG 传感器通过中心波长的漂移量来实现传感^[13]。FBG 传感器中心波长的表达式为

$$\lambda_B = 2n_{\text{eff}}\Lambda, \quad (1)$$

式中: n_{eff} 为光纤的有效折射率; Λ 为光栅周期。当外界应力发生变化时,光纤的有效折射率和光栅周期都会发生变化,从而导致 FBG 反射光中心波长发生漂移,因此通过测量 FBG 中心波长的漂移量 $\Delta\lambda$ 就可以确定外界应变的大小。 $\Delta\lambda$ 与应变之间的关系式为

$$\Delta\lambda_B/\lambda_B = (1 - p_e)\epsilon, \quad (2)$$

式中: p_e 为光纤的弹光系数; ϵ 为 FBG 受到的应变。

根据上述测量原理,齿轮在运行时产生的机械振动会对安装在箱体表面的 FBG 传感器产生应力作用,通过测量 FBG 传感器的波长偏移量,就能采集到齿轮的振动信号。对振动信号中的频率分量进行分析,并提取瞬变、调幅或调频等非平稳、非线性特征是齿轮故障识别的关键^[14]。

2.2 算法原理

2.2.1 EMD 算法的改进

EMD 算法能将非平稳信号分解为不同频率成分的 IMF 分量,但必须满足两个条件^[15]:1)在整个信号范围内,IMF 分量极大值和极小值点的数目最多相差 1;2)在任意时刻,由上下包络线计算的平均曲线为 0 或者近似为 0。但 EMD 算法容易出现模态混叠问题,即同一 IMF 分量中含有不同尺度的分量,导致无法提取齿轮的故障特征。模态混叠主要是由信号频谱的间断性导致的,而高斯白噪声具有零均值特性,其功率谱服从均匀分布,在振动信号中加入白噪声能改善频谱的间断性^[16],有效解决模态混叠问题。然而,若加入的噪声功率选择不合适,不但无法消除模态混叠,甚至还会在 IMF 分量中产生严重的噪声干扰。对此,本文提出了一种自适应噪声补偿聚合经验模态分解(ANCEEMD)算法,具体步骤如下。

步骤 1: 随机生成 N 个高斯白噪声序列 $n_i(t)$, $i=1,2,3,\dots,N$, 利用 EMD 算法对其进行分解,公式为

$$n_i(t) = \sum_{k=1}^u \omega_{i,k}(t) + r'_i(t), \quad (3)$$

式中, $\omega_{i,k}(t)$ 表示第 i 个高斯白噪声的第 k 阶 IMF 分量; u 为 IMF 分量的最高阶数; t 为时间; $r'_i(t)$ 为第 i 个高斯白噪声的残余分量。

步骤 2: 在信号 $x(t)$ 中添加 N 组步骤 1 中的高斯白噪声,使其正负极性相反,即

$$\begin{bmatrix} X_i^+(t) \\ X_i^-(t) \end{bmatrix} = \begin{bmatrix} 1 & \alpha_0 \\ 1 & -\alpha_0 \end{bmatrix} \begin{bmatrix} x(t) \\ n_i(t) \end{bmatrix}, \quad (4)$$

式中 α_0 为初始噪声功率。

步骤 3: 对 $X_i^+(t)$ 和 $X_i^-(t)$ 进行 EMD 分解,每次分解出第一阶 IMF 分量后停止,记分量分别为 $c_{i,1}^+(t)$ 和 $c_{i,1}^-(t)$,并对所有的第一分量求平均,由此可得到原始信号的第一阶 IMF 分量,即

$$C_1(t) = \frac{1}{2N} \sum_{i=1}^{2N} [c_{i,1}^+(t) + c_{i,1}^-(t)]. \quad (5)$$

步骤 4: 计算原始信号 $x(t)$ 的第一阶残余分

量,即

$$r_1(t) = x(t) - C_1(t). \quad (6)$$

步骤 5: 将高斯白噪声对应的第 j 阶 IMF 分量 $w_{i,j}(t)$ 分别加入第 j 阶残余分量 $r_j(t)$ 中,得到新的残余分量 $R_i^+(t)$ 和 $R_i^-(t)$,即

$$\begin{bmatrix} R_i^+(t) \\ R_i^-(t) \end{bmatrix} = \begin{bmatrix} 1 & \alpha_j \\ 1 & -\alpha_j \end{bmatrix} \begin{bmatrix} r_j(t) \\ w_{i,k}(t) \end{bmatrix}, \quad (7)$$

式中: α_j 为新残余分量中噪声功率的系数。

步骤 6: 令 $X_i^+(t)$ 和 $X_i^-(t)$ 分别等于 $R_i^+(t)$ 和 $R_i^-(t)$,重复步骤 2~5,直到不满足 EMD 分解条件。

步骤 7: 最后,可以得到原始振动信号 $x(t)$ 的所有 IMF 分量,记为

$$x(t) = \sum_{k=1}^m C_k(t) + r_n(t), \quad (8)$$

式中: $C_k(t)$ 表示第 k 阶 IMF 分量; m 为 IMF 分量的总数; $r_n(t)$ 表示残余分量。

在算法分解阶段,根据系数 α_j 可以自适应选择加入高斯白噪声功率的大小,其定义为

$$\alpha_j = \epsilon_s \cdot \sigma_j, \quad (9)$$

式中: ϵ_s 表示高斯初始白噪声序列 $n_i(t)$ 的标准差; σ_j 表示第 j 阶残差分量 $r_j(t)$ 的标准差, $j=0,1,2,\dots,m$ 。经实验分析可知,将 ϵ 值设为 0.2 时具有最佳的分解效果。

因此,采用 ANCEEMD 算法可将齿轮振动信号分解成不同模态的时频分量,频率从高到底依次递减。但并非所有分量都包含有用信号,为此,需要寻求确定有效 IMF 分量的方法。

2.2.2 有效 IMF 分量的确定

1) 相关系数

信号的相关性可有效表征信号之间的线性关系或相似程度^[17]。因此,原始信号 $x(t)$ 与 IMF 分量之间的相关性可以反映 IMF 分量携带有用信息的程度,相关系数越大,表明 IMF 分量包含的有用信息越多。因此可以将相关系数作为选择有效分量的一个指标。相关系数 P 的表达式为

$$P = \frac{\sum_{t=1}^n [C(t) - \bar{C}(t)][x(t) - \bar{x}(t)]}{\sqrt{\sum_{t=1}^n [C(t) - \bar{C}(t)]^2 \sum_{t=1}^n [x(t) - \bar{x}(t)]^2}}, \quad (10)$$

式中: n 为信号样点数; $\bar{C}(t)$ 和 $\bar{x}(t)$ 分别为 IMF 分量和振动信号的平均值。

2) 峭度值

当齿轮出现故障时,振动信号中会产生冲激响

应。峭度对冲激信号非常敏感。当齿轮正常运行时,振动信号服从正态分布,峭度值为常量^[18](通常为 3);当齿轮出现故障时,信号幅值会偏离正态分布,峭度值会随之增大。峭度值越大,表明振动信号中的冲激分量越明显,因此将其作为选择 IMF 有效分量的另一指标。峭度 K 的计算公式为

$$K = \frac{\frac{1}{n} \sum_{t=1}^n [C(t) - \bar{C}(t)]^4}{\left\{ \frac{1}{n} \sum_{t=1}^n [C(t) - \bar{C}(t)]^2 \right\}^2}. \quad (11)$$

3) 综合评价指标

上述指标仅从不同的角度反映了 IMF 分量的特性,为了更全面地反映 IMF 分量包含的有用信息,本文提出采用综合评价指标 T_{index} 来衡量 IMF 分量的有效性。该指标的定义为

$$T_{\text{index}} = P \cdot K. \quad (12)$$

T_{index} 值越大,表明对应的 IMF 分量含有的齿轮故障信息越多。同时,将综合评价指标的均值作为有效 IMF 分量的筛选条件,即

$$T_{\text{index}}^i \geq \frac{1}{m} \sum_{i=1}^m T_{\text{index}}^i, \quad (13)$$

式中: T_{index}^i 表示第 i 阶 IMF 分量的综合评价指标值。

2.3 特征提取与分类

齿轮在故障状态时会产生弱冲激分量,提取 IMF 分量的多种特征有助于提高齿轮故障识别的准确率。故采用 4 种具有代表性的指标来提取特征。

1) IMF 分量的方差

齿轮状态出现异常时,信号会产生较大波动,从而使方差产生变化。因此,用 IMF 分量的方差来表示齿轮的故障特征,其定义为

$$S = \frac{1}{n-1} \sum_{t=1}^n [C(t) - \bar{C}(t)]^2. \quad (14)$$

2) IMF 分量的中心频率

由于 IMF 分量可以表示不同频率成分的信号,且每种故障状态下信号的中心频率均不同,因此将 IMF 分量的中心频谱作为齿轮故障的另一个特征。采用(15)式对所有 IMF 分量进行傅里叶变换,可以得到该分量的频谱图,其中心频率为频谱峰值对应的频率。

$$F(k) = \sum_{t=0}^{n-1} x(t) \exp\left(-j \frac{2\pi}{N} kt\right), \quad (k=0,1,\dots,n-1). \quad (15)$$

3) 中心频率处的幅值

齿轮出现不同的故障状态时,对应 IMF 分量的

频谱幅值也会产生差异,因此可以将频谱峰值作为齿轮故障的另一个特征。

4) 信号能量熵

齿轮出现故障时,信号在不同频率段的能量分布会发生不同程度的变化,能量熵能体现信号能量之间的差异,因此可以将其作为齿轮故障的特征。能量熵 H 的公式为

$$H = - \sum_{d=1}^n (E_d / E_{\text{sum}}) \ln(E_d / E_{\text{sum}}), \quad (16)$$

式中: E_d 和 E_{sum} 分别表示 IMF 分量样点的能量及其总能量; d 表示样点数量。

采用上述方法提取 IMF 分量的特征并组成特征向量,利用支持向量机(SVM)进行训练与识别^[19]。由于传统的 SVM 是一种二分类器,而齿轮故障问题属于多分类问题,因此,利用二叉树原理将 SVM 改进成多分类器,以满足需要。

3 仿真实验验证

3.1 模态混叠效应消除的验证

为了验证所提 ANCEEMD 算法能有效消除模态混叠效应,首先对仿真信号进行验证。本文在参考文献[4]的基础上给出了仿真实验信号的表达式,即

$$\begin{cases} x_1(t) = \exp(-400t_1) \sin(2\pi f_1 t), t_1 = \\ \quad \text{mod}(t, 1/f_B) \\ x_2(t) = \sin(2\pi f_2 t) \\ x_3(t) = \sin(2\pi f_3 t) \\ x(t) = x_1(t) + x_2(t) + x_3(t) \end{cases} \quad (17)$$

式中: $x_1(t)$ 为模拟齿轮的振动信号; $x_2(t)$ 和 $x_3(t)$ 分别为不同周期的正弦信号,对应齿轮产生的故障信号; $x(t)$ 为 $x_1(t)$ 、 $x_2(t)$ 和 $x_3(t)$ 的叠加信号,其信号的波形图如图 1 所示; $f_1 = 500 \text{ Hz}$, $f_2 = 50 \text{ Hz}$, $f_3 = 20 \text{ Hz}$, $f_B = 10 \text{ Hz}$; $\text{mod}(\cdot)$ 为求模表达式。

利用 EMD 和 ANCEEMD 算法分别对信号 $x(t)$ 进行分解,得到其 IMF 分量,如图 2 所示(纵轴为各 IMF 分量的幅值 A)。与图 1 比对后发现,采用 EMD 分解会导致严重的模态混叠现象,如图 2(a)所示。从图 2(b)中可以发现,采用 ANCEEMD 分解后,IMF2~IMF3 波形能分别复现图 1 中的 $x_1(t)$ 、 $x_2(t)$ 和 $x_3(t)$ 信号,这表明所提算法可以有效抑制模态混叠效应。

3.2 综合评价指标有效性的验证

采用 ANCEEMD 算法分解后,可分别计算出

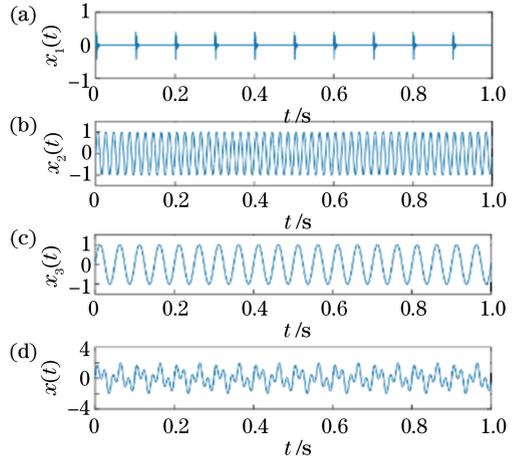


图 1 仿真信号及其分量图。(a)脉冲信号; (b) 50 Hz 信号; (c) 20 Hz 信号; (d) 合成信号

Fig. 1 Simulated signal and its components. (a) Pulse signal; (b) 50 Hz signal; (c) 20 Hz signal; (d) composite signal

IMF1~IMF5 的相关系数(P)、峭度值(K)、综合评价指标(T_{indx})及它们的平均值,如表 1 所示。分析表 1 可知: IMF1 对应的冲激分量的相关系数较小,仅有 IMF2 和 IMF3 对应的相关系数大于均值,若仅利用相关系数作为评价指标,就会漏选冲激分量 IMF1; 同理,若仅用峭度值来确定有效分量,则只有 IMF1 满足要求,会造成故障信息 IMF2 和 IMF3 的漏选; 当选用综合评价指标(T_{indx})来确定有效分量时,IMF1~IMF3 的综合评价指标均大于其均值(0.4491)。综合评价指标不但包含了振动信息,还包含了故障信息,即可以较完整地将有效分量准确筛选出来,说明了该综合评价指标的有效性。

4 实验与分析

4.1 实验平台的搭建

如图 3 所示为搭建的齿轮故障检测实验平台。在实验中,将 2 个中心波长均为 1545 nm 的 FBG 传感器利用丙烯酸酯粘贴在小型车床的主轴箱(齿轮箱)上,其中一个 FBG 粘贴在主轴箱(齿轮箱)上部,另一个 FBG 粘贴在侧面。光纤光栅解调仪的型号为 FI-104,其解调频率为 2000 Hz,解调波长范围为 1525~1565 nm。

小型车床齿轮箱简化结构简图如图 4 所示,其中 5# 齿轮为主动轮,7# 齿轮为主轴输出齿轮,1# 齿轮为丝杆输出轴齿轮。齿轮的主要参数如表 2 所示。

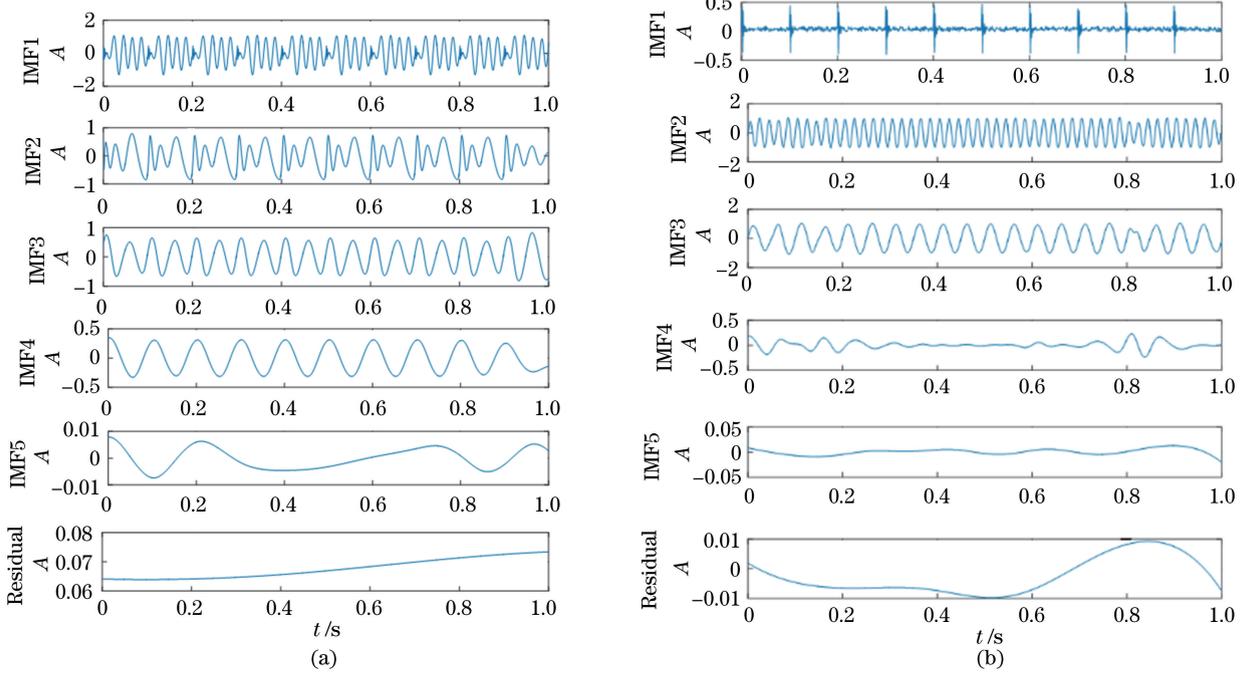


图 2 采用不同算法分解得到的 IMF 分量图。(a) EMD 算法;(b) ANCEEMD 算法

Fig. 2 IMF components obtained by different algorithms. (a) EMD algorithm; (b) ANCEEMD algorithm

表 1 三种评价指标的数值表

Table 1 Numerical table of three evaluation indicators

Indicator	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	Mean
P	0.0194	0.7055	0.7251	-0.0021	-0.0190	0.0025	0.2386
K	27.0810	1.5490	1.5683	4.1677	2.9263	1.4472	6.4546
T_{indx}	0.5254	1.0929	1.1372	-0.0089	-0.0555	0.0036	0.4491

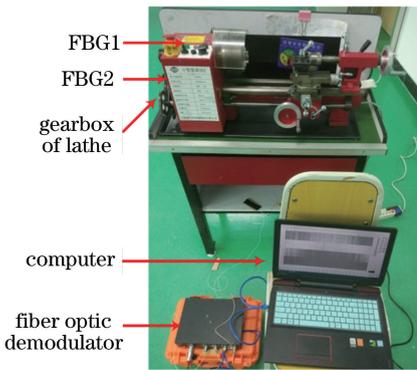


图 3 齿轮故障检测平台

Fig. 3 Gearbox fault detection platform

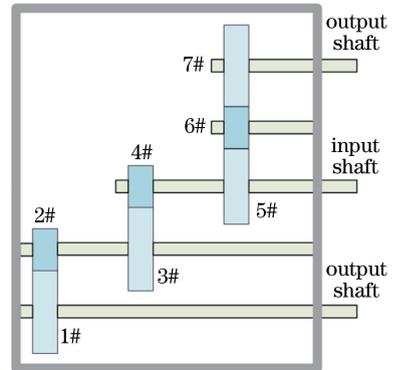


图 4 齿轮箱结构简图

Fig. 4 Simplified structure of lathe gear box

表 2 齿轮参数表

Table 2 Gear parameter table

Gear	1 #	2 #	3 #	4 #	5 #	6 #	7 #
Number of teeth	80	20	80	20	40	25	60
Reference diameter /mm	80	20	80	20	40	25	60
Module	1	1	1	1	1	1	1
Angle of pressure /($^{\circ}$)	20	20	20	20	20	20	20

4.2 实验步骤

为验证所提齿轮故障检测方法的有效性,以车床主轴箱中的 3#、4# 和 6# 齿轮作为研究对象,分别对 6 种不同状态(正常、轻度磨损、重度磨损、点蚀、裂纹、断齿)

蚀、裂纹以及断齿)下的齿轮进行测试,每种状态的信号均采集 400 个样本。图 5(a)~(f)分别为 3# 齿轮在不同工况下的实物图,其中,椭圆圈部分为齿轮的故障位置。

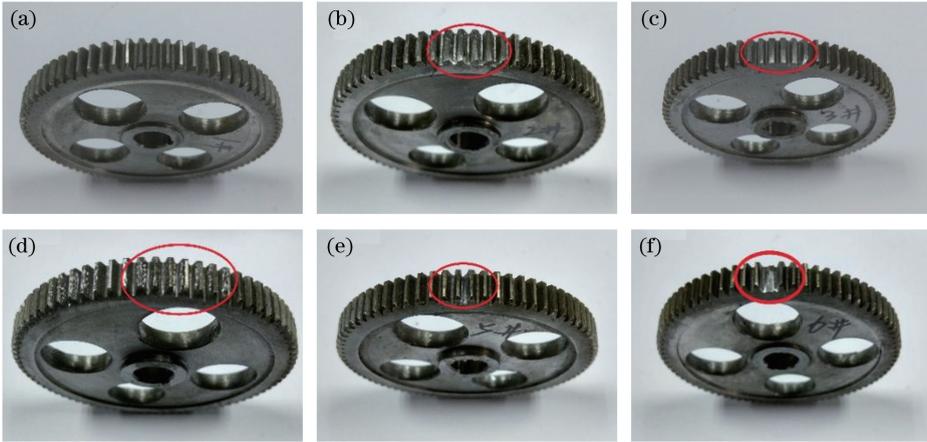


图 5 6 种不同状态的 3# 齿轮。(a)正常;(b)轻度磨损;(c)重度磨损;(d)点蚀;(e)裂纹;(f)断齿
Fig. 5 Six different states of 3# gear. (a) Normal; (b) mild wear; (c) severe wear; (d) pitting; (e) crack; (f) broken teeth

图 6 给出了齿轮故障的实验检测流程。通过安装在齿轮箱外表面的 FBG 传感器采集振动信号,并对所采集的信号进行降噪;再采用所提 ANCEEMD 算法分解振动信号,并选择有效 IMF 分量;最后进行特征提取,将提取的特征作为齿轮故障分类与识别的依据。

标。对采集的信息进行解调与分析后发现,在相同的条件下,两支光栅采集的齿轮箱的振动信号非常相似。因此,选用信噪比大的作为所需的振动信号。以 3# 齿轮为例,在 6 种不同的工况下,通过 FBG 传感器采集了振动信号的时域波形图,如图 7 所示。

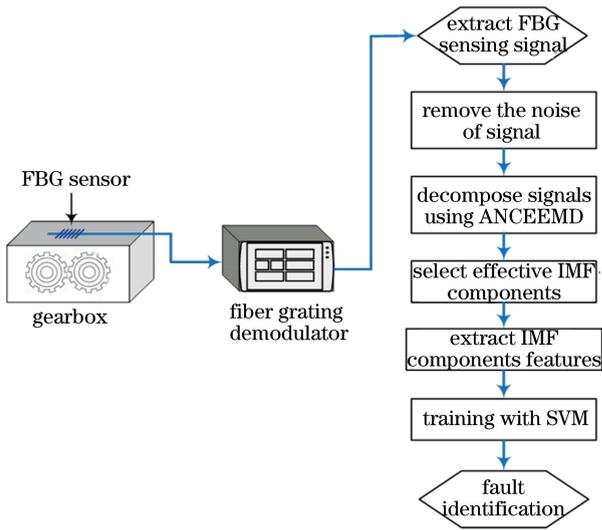


图 6 齿轮故障检测流程图

Fig. 6 Gearbox fault detection flow chart

4.3 信息的提取与处理

为了更好地、更全面地采集相关信息,采用两个相同型号的布拉格光栅进行传感,并将其分别粘贴于齿轮箱的上部和侧面。实验中,在 1 s 内采集 2000 次波长漂移量,以时间为横坐标,波长漂移量 $\Delta\lambda$ 为纵坐

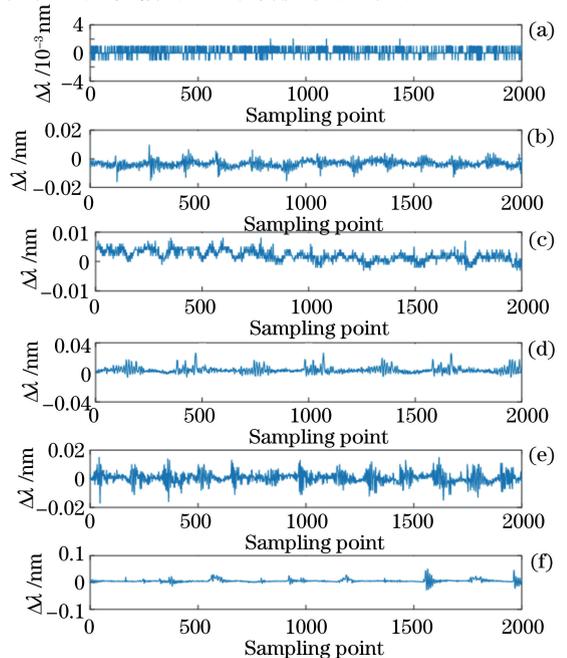


图 7 不同状态的 3# 齿轮的时域信号图。(a)正常;(b)轻度磨损;(c)重度磨损;(d)点蚀;(e)裂纹;(f)断齿
Fig. 7 Time domain signal diagrams of 3# gear in different states. (a) Normal; (b) mild wear; (c) severe wear; (d) pitting; (e) crack; (f) broken teeth

图 7(a)是正常情况下的波形图,分析后可知,此时 FBG 传感器的中心波长漂移量最小,基本维持在 1 pm 附近。当发生断齿时,FBG 传感器的中心波长漂移量最大,接近 50 pm,如图 7(f)所示。与图 7(a)进行对比后可以发现,6 种信号在时域上均有差异,表明 FBG 传感器可以有效采集齿轮的不同故障信息。

由于所采集的信号中还含有噪声,因此,首先参考文献[20]的 ITBOMP 算法对振动信号进行降噪处理,再采用所提 ANCEEMD 算法对时域信号进行分解。现以正常和断齿工况下所采集的信号进行分析。从图 8(b)和图 9(b)中可以看出:振动信号可分成 9 个 IMF 分量和一个残余分量;所有分量的频率幅值 A 都呈现出从低频向高频衰减的趋势,不同频率段的中心频率都能正确分解到对应的 IMF 分量中,从而有效避免了模态混叠。同时可以发现,正常齿轮频域分布与故障状态下 IMF 分量的频域分布有很大区别,尤其是 IMF1 分量。正常齿轮的 IMF1 能量主要集中于 450 Hz 左右,而故障状态齿轮的能量主要集中在 190 Hz 附近,这表明齿轮从正常状态变成故障状态时,其频域分布会发生改变。对其他故障的齿轮重复上述实验后发现,其频域分布情况也不尽相同,说明频域分布可以用来表征齿轮的不同故障。

然后,在消除信号模态混叠的基础上,根据

(10)~(12)式分别计算出图 8(b)和图 9(b)中 IMF1~IMF9 的相关系数、峭度值和综合评价指标,并利用(13)式所示的约束条件进行判断(由于篇幅原因相关数据不在此罗列),此时 IMF1~IMF4 的综合评价指标均大于均值,即前 4 个 IMF 为有效分量。在此基础上分别提取前 4 个有效分量的方差、特征频率、最大幅值及能量熵,并将其组成 4 维向量 T_1 。对 IMF2~IMF4 重复上述过程,分别组成 T_2 、 T_3 和 T_4 向量。最后将 IMF1~IMF4 有效分量的特征组合成 16 维特征向量 C ,并利用 SVM 进行训练。实验中每种状态下的信号均采集 400 个样本,其中 75% 的样本用于训练,25% 的样本用于齿轮故障的识别。

4.4 实验结果与分析

为验证所提方法的有效性,将所提 ANCEEMD 算法与 EMD、EEMD 以及 CEEMD 算法进行对比;同时,为了体现 SVM 小样本学习的优势,将其与 BP 神经网络算法^[21]进行对比。表 3~5 分别给出了 3#、4# 以及 6# 齿轮的识别精度,可以发现:ANCEEMD 算法对齿轮故障的识别精度均高于对比算法;与 BP 神经网络相比,SVM 的识别效果要优于 BP 神经网络,体现了 SVM 在小样本分类中的优势。

实验结果表明,所提算法能有效降低模态混叠效应,同时能准确识别齿轮的不同故障,识别率均在 90% 以上。

表 3 3# 齿轮故障类型的识别结果

Table 3 Fault type identification result of 3# gear

Method	Rate of identification / %					
	Normal	Mild wear	Severe wear	Pitting	Crack	Broken teeth
EMD+SVM	73	60	80	87	90	93
EEMD+SVM	82	77	85	90	91	96
CEEMD+SVM	89	90	93	92	91	96
ANCEEMD+BP	85	90	92	89	92	97
ANCEEMD+SVM	93	92	94	95	97	99

表 4 4# 齿轮故障类型识别结果

Table 4 Fault type identification result of 4# gear

Method	Rate of identification / %					
	Normal	Mild wear	Severe wear	Pitting	Crack	Broken teeth
EMD+SVM	66	70	71	85	87	90
EEMD+SVM	71	65	80	89	92	94
CEEMD+SVM	88	87	90	92	92	94
ANCEEMD+BP	90	87	84	87	93	96
ANCEEMD+SVM	96	93	90	99	95	99

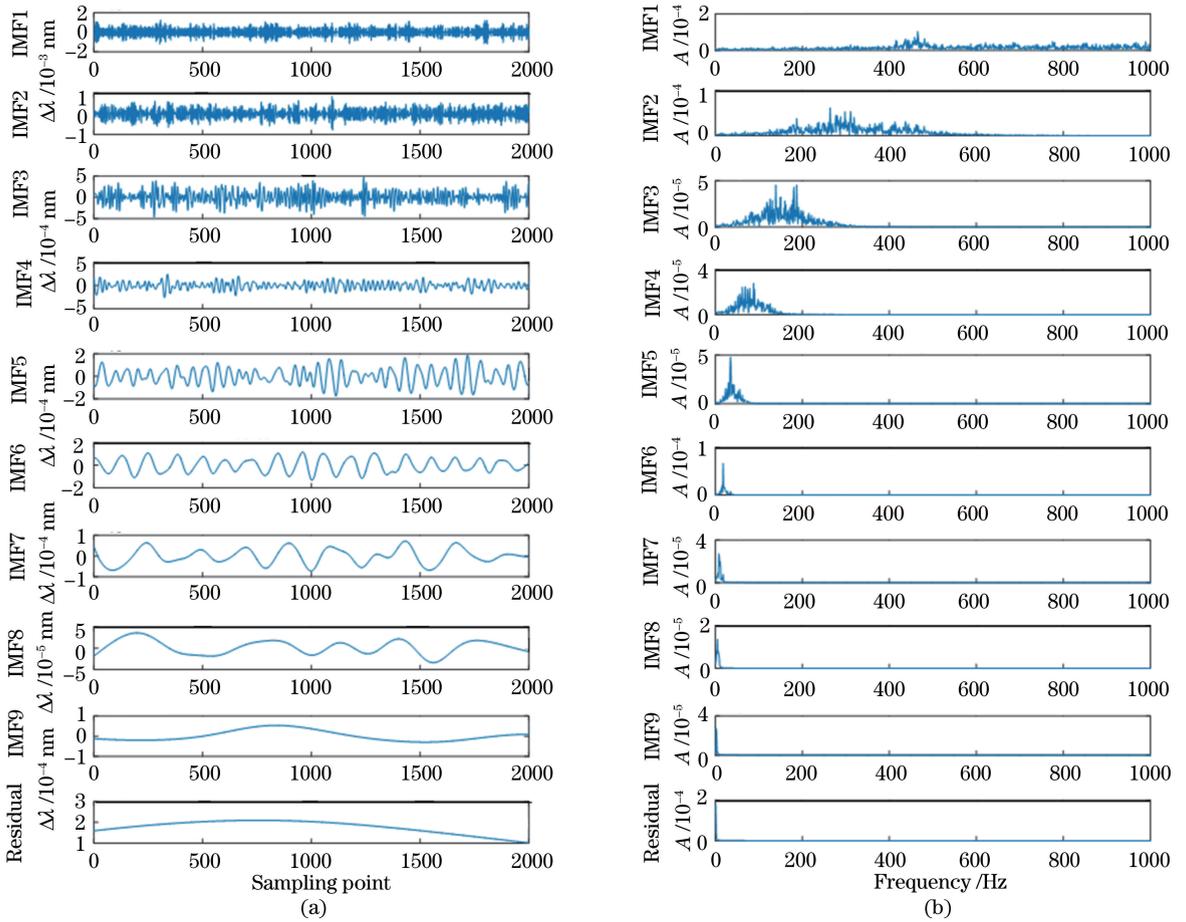


图 8 正常状态下的 IMF 分量及其频域分布。(a) IMF 分量;(b)对应分量的频域分量图
 Fig. 8 IMF components and their frequency domain distribution under normal condition.
 (a) IMF component; (b) frequency domain distribution of the corresponding components

表 5 6# 齿轮故障类型识别结果

Table 5 Fault type identification result of 6# gear

Method	Rate of identification / %					
	Normal	Mild wear	Severe wear	Pitting	Crack	Broken teeth
EMD+SVM	78	83	85	80	86	91
EEMD+SVM	81	83	88	84	87	96
CEEMD+SVM	84	87	91	93	95	94
ANCEEMD+BP	84	74	90	89	93	95
ANCEEMD+SVM	99	95	96	93	97	98

5 结 论

针对齿轮故障检测问题,本文提出了一种基于自适应噪声补偿聚合经验模态分解(ANCEEMD)算法的齿轮故障识别方法。利用自适应补偿高斯白噪声的方式使原始信号的频谱更为均匀,以降低模

态混叠;同时提出了一种选择有效 IMF 分量的综合评价指标,并提取了有效分量的 4 种特征;最后利用 SVM 进行训练与识别。实验结果表明,所提方法能有效识别齿轮的多种故障类型,识别率均在 90% 以上。本文所提方法为齿轮故障识别提供了一种有效的参考。

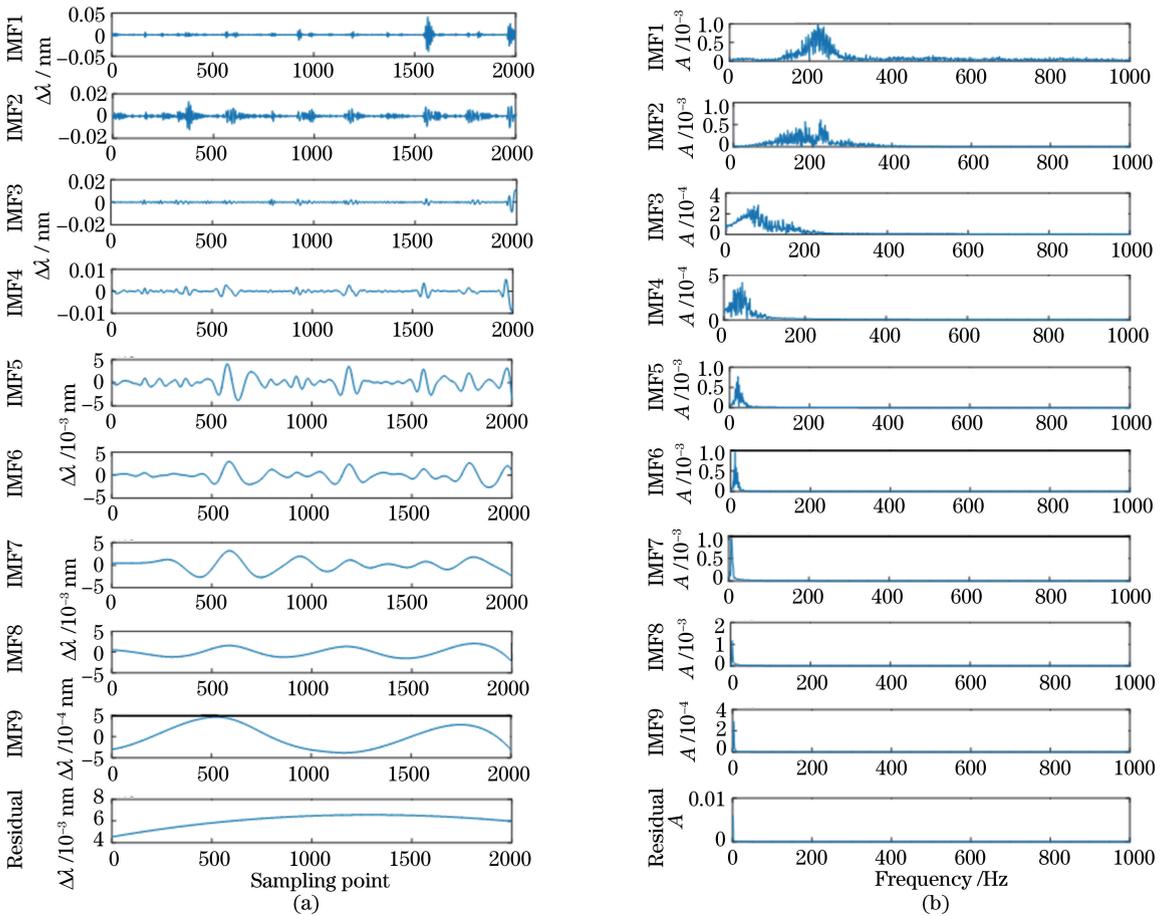


图 9 断齿状态下的 IMF 分量及其频域分布图。(a) IMF 分量;(b)对应分量的频域分量图

Fig. 9 IMF components and their frequency domain distribution under broken condition.

(a) IMF component; (b) frequency domain distribution of the corresponding components

参 考 文 献

[1] Jiang G Q, He H B, Yan J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox [J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3196-3207.

[2] Yang Q, Hu C Z, Zheng N G. Data-driven diagnosis of nonlinearly mixed mechanical faults in wind turbine gearbox[J]. IEEE Internet of Things Journal, 2018, 5(1): 466-467.

[3] Zhou W, Liang Q. Real-time spectrum analysis algorithm for non-stationary signal and its implementation on FPGA platforms [J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2018, 30(5): 633-641.
周围, 梁琦. 非平稳信号实时谱分析算法及其 FPGA 实现[J]. 重庆邮电大学学报(自然科学版), 2018, 30(5): 633-641.

[4] Wang J, Cheng F Z, Qiao W, et al. Multiscale filtering reconstruction for wind turbine gearbox fault diagnosis under varying-speed and noisy conditions

[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4268-4278.

[5] Zhang M, Wang K S, Wei D D, et al. Amplitudes of characteristic frequencies for fault diagnosis of planetary gearbox [J]. Journal of Sound and Vibration, 2018, 432: 119-132.

[6] Chen Y, Wu C T, Liu H L. EMD self-adaptive selecting relevant modes algorithm for FBG spectrum signal[J]. Optical Fiber Technology, 2017, 36: 63-67.

[7] Amarnath M, Praveen Krishna I R. Local fault detection in helical gears via vibration and acoustic signals using EMD based statistical parameter analysis[J]. Measurement, 2014, 58: 154-164.

[8] Pan P, Xi L X, Zhang X G, et al. Experimental research on polarization mode dispersion measurement based on empirical mode decomposition [J]. Chinese Journal of Lasers, 2018, 45 (1): 0106002.
潘潘, 席丽霞, 张晓光, 等. 基于经验模态分解的偏振模色散测量实验研究[J]. 中国激光, 2018, 45(1): 0106002.

- [9] Chen J Y, Zhou D, Liu C, et al. An integrated method based on CEEMD-SampEn and the correlation analysis algorithm for the fault diagnosis of a gearbox under different working conditions[J]. Mechanical Systems and Signal Processing, 2018, 113: 102-111.
- [10] Zhao C R, Jin X F, Ni D C, et al. Optical fiber rotational speed sensor based on plastic optical fiber and optical prism [J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2016, 28(3): 383-388.
赵呈锐, 金晓峰, 倪大成, 等. 基于塑料光纤和棱镜结构的光纤式转速传感器[J]. 重庆邮电大学学报(自然科学版), 2016, 28(3): 383-388.
- [11] Chen Y, Liu B L, Liu H L, et al. Load location and measurement system based on fiber Bragg grating sensor [J]. Chinese Journal of Mechanical Engineering, 2016, 52(18): 8-15.
陈勇, 刘保林, 刘焕淋, 等. 基于光纤布拉格光栅的载荷定位与检测方法[J]. 机械工程学报, 2016, 52(18): 8-15.
- [12] Chen Y, Zhou L X, Liu H L. A fiber Bragg grating sensor perimeter intrusion localization method optimized by improved particle swarm optimization algorithm[J]. IEEE Sensors Journal, 2018, 18(3): 1243-1249.
- [13] Liu H L, Wang C J, Chen Y. An improved genetic algorithm for increasing the addressing accuracy of encoding fiber Bragg grating sensor network [J]. Optical Fiber Technology, 2018, 40: 28-35.
- [14] He C B, Cai S K, Sun D K, et al. Fault diagnosis of wind turbine planetary gearbox based on order analysis and divergence index [J]. The Journal of Engineering, 2017, 2017(13): 1394-1398.
- [15] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [16] Lian J J, Rong Q B, Dong X F, et al. Structural model parameter identification method based on an improved HHT for suppressing mode mixing [J]. Journal of Vibration and Shock, 2018, 37(18): 1-8.
练继建, 荣钦彪, 董霄峰, 等. 抑制模态混叠的 HHT 结构模态参数识别方法研究[J]. 振动与冲击, 2018, 37(18): 1-8.
- [17] Zhang X, Cui W, Liu Y L. Recovery of structured signals with prior information via maximizing correlation [J]. IEEE Transactions on Signal Processing, 2018, 66(12): 3296-3310.
- [18] Zhang L, Mao Z D, Yang S X, et al. An improved Kurtogram based on band-pass envelope spectral Kurtosis with its application in bearing fault diagnosis [J]. Journal of Vibration and Shock, 2018, 37(23): 171-179.
张龙, 毛志德, 杨世锡, 等. 基于包络谱带通峭度的改进谱峭度方法及在轴承诊断中的应用[J]. 振动与冲击, 2018, 37(23): 171-179.
- [19] Pan X L, Yang Z J, Xu Y T, et al. Safe screening rules for accelerating twin support vector machine classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(5): 1876-1887.
- [20] Chen Y, Liu Z Q, Liu H L. A method of fiber Bragg grating sensing signal de-noise based on compressive sensing[J]. IEEE Access, 2018, 6: 28318-28327.
- [21] Geng R, Wang X J, Ye N, et al. A fault prediction algorithm based on rough sets and back propagation neural network for vehicular networks [J]. IEEE Access, 2018, 6: 74984-74992.