

基于 IITD 和 FCM 聚类的滚动 轴承故障诊断

向 玲, 郭鹏飞, 高 楠, 张力佳
(华北电力大学 机械工程系, 河北 保定 071003)

摘 要: 基于 Akima 插值和固有时间尺度分解(ITD)中的线性变换,提出了一种改进的固有时间尺度分解(IITD),在此基础上,进一步提出基于 IITD 近似熵(AE)和模糊 C 均值聚类(FCM)相结合的滚动轴承故障的诊断方法。采用 IITD 方法对滚动轴承的振动信号进行分解,通过互信息分析,筛选出前 3 个含主要特征信息的固有旋转分量(PR),计算其近似熵值作为信号的特征向量,将得到的特征向量输入到 FCM 分类器中分析并得到分类结果。实验分析表明:分别与基于 EMD、ITD 近似熵和 FCM 聚类相结合的方法比较,该方法的分类系数更接近 1,平均模糊熵更接近 0,即此方法对滚动轴承的正常、内圈故障、外圈故障、滚动体故障信号以及对内圈的不同损伤程度信号均能更有效更准确地进行分类。

关 键 词: 故障诊断; 滚动轴承; 改进固有时间尺度分解(IITD); 模糊 C 均值聚类(FCM); 近似熵
中图分类号: V233; TH165 **文献标志码:** A

Rolling bearing fault diagnosis based on IITD and FCM clustering

XIANG Ling, GUO Pengfei, GAO Nan, ZHANG Lijia

(School of Mechanical Engineering,
North China Electric Power University, Baoding Hebei 071003, China)

Abstract: An improved intrinsic time-scale decomposition (IITD) method was proposed based on Akima interpolation and linear transformation of intrinsic time-scale decomposition (ITD). Furthermore, based on approximate entropy (AE) and fuzzy C-means clustering (FCM), a new analysis method of using IITD for fault vibration signal of rolling bearing was proposed as well. The vibration signal was decomposed with IITD to obtain a certain number of proper rotation (PR) and a trend. By using mutual information analysis, three PR components were sifted out and the AE was calculated as the eigenvectors. The constructed eigenvectors were put into FCM classifier to recognize different fault types. These results were compared with the methods based on empirical mode decomposition (EMD) and ITD approximate entropy and FCM respectively. The classification coefficient with use of this method was calculated more closer to 1 and average fuzzy entropy was calculated more closer to 0. Accurate fault identification was presented for roller bearing's normal, inner faults, outer faults, rolling body fault signals and different damage degree signals of rolling body faults.

收稿日期: 2017-05-24

基金项目: 国家自然科学基金(51675178)

作者简介: 向玲(1971—),女,教授、博士生导师,博士,从事故障诊断与状态监测研究。

引用格式: 向玲,郭鹏飞,高楠,等. 基于 IITD 和 FCM 聚类的滚动轴承故障诊断[J]. 航空动力学报,2018,33(10):2553-2560.
XIANG Ling, GUO Pengfei, GAO Nan, et al. Rolling bearing fault diagnosis based on IITD and FCM clustering[J]. Journal of Aerospace Power, 2018, 33(10): 2553-2560.

Key words: fault diagnosis; rolling bearing;
improved intrinsic time-scale decomposition (IITD);
fuzzy C-meansclustering (FCM); approximate entropy

滚动轴承是旋转机械设备中应用最广泛的器件之一,其缺陷和损伤将直接影响整个机械设备的性能和寿命^[1]。因此,滚动轴承的故障特征提取和故障分类对机械设备的正常作业有很重要的工程实际意义。

向丹等^[2]采用 EMD 把滚动轴承的振动信号分解为各阶本征模函数(intrinsic mode function, IMF),计算各 IMF 分量的多种熵值,并进行特征信息融合作为支持向量机的输入,实现了滚动轴承故障诊断;王军辉等^[3]针对 EMD 的模式混叠,采用集成经验模态分解(ensemble empirical mode decomposition, EEMD)提取风电机组齿轮箱齿轮故障特征,并用奇异谱熵值作为模糊聚类的输入参数,对齿轮的不同损伤状态进行识别分类;杨宇等^[4]采用局部均值分解(local mean decomposition, LMD)获得各分量的包络谱特征值,输入到支持向量机,成功对滚动轴承故障类型和状态进行分类区分;段礼祥等^[5]采用 ITD 方法把齿轮箱故障信号分解为多阶 PR 分量,求取其特征能量作为故障特征向量,并输入 FCM 分类器中进行聚类识别,诊断结果比基于 EMD 方法的聚类识别效果要好。

近年来,基于 EMD、LMD 和 ITD 进行故障特征提取已经得到了广泛的关注^[1-5],众多学者也逐渐表示三类方法都存在一定局限性。EMD 和 LMD 都属于递归模式分解方法,在分解过程中由于包络线估计误差的传播,导致模式混叠现象发生,同时两种方法存在端点效应问题^[6-7],且 EMD 还存在过包络、欠包络等缺陷。虽然加入白噪声法对 EMD 进行了改进,但该方法加大了运算量且会出现多个虚假分量^[8]。Frei 等^[9]提出了 ITD 方法,并与 EMD 方法进行了比较,ITD 方法虽然在计算效率和处理端点效应方面有明显的优势,但由于 ITD 方法对基线的定义是基于信号本身的线性变换,使分解得到的 PR 分量的波形出现毛刺而失真^[10]。

基于上述的研究,作者提出了 Akima 插值和 ITD 相结合的 IITD 方法。在此基础上,进一步通过 IITD 把滚动轴承故障信号分解为各阶 PR 分量,然后通过互信息法,获取前 3 阶包含故障信息的真实分量的近似熵值作为特征向量,输入到

FCM 分类器中作聚类识别。实验结果分别与基于 EMD、ITD 的聚类方法相比较,证明该方法能够对滚动轴承的不同故障类型信号以及不同损伤程度的故障信号进行更有效、更精确的识别分类。

1 IITD 方法

1.1 ITD 方法

对于任意给定的一个非线性非平稳信号 X_t ,定义 L 为基线提取算子,则信号 X_t 的一次分解为 $X_t = LX_t + (1-L)X_t = L_t + H_t$,其中 L_t 为基线信号, H_t 为固有旋转分量,则 ITD 算法步骤为^[9-10]:

1) 求出信号 $\{X_t, t \geq 0\}$ 的全部极值点 X_k 及其相应的时刻 $\tau_k \{k=1, 2, \dots, M\}$, M 为极值点总数,定义初始时刻 $\tau_0=0$ 。

2) 在连续极值点间隔区间 $[\tau_k, \tau_{k+1}]$ 上,定义分段线性基线提取算子

$$LX_t = L_t = L_k + \frac{L_{k+1} - L_k}{X_{k+1} - X_k}(X_t - X_k) \quad (1)$$

式中

$$L_{k+1} = \alpha \left[X_k + \frac{\tau_{k+1} - \tau_k}{\tau_{k+2} - \tau_k}(X_{k+2} - X_k) \right] + (1-\alpha)X_{k+1} \quad (2)$$

式中 L_k, L_{k+1} 为第 k 个和第 $k+1$ 个基线控制点; $\alpha \in (0, 1)$, 通常取 0.5。

3) 将基线信号视为原始信号,循环上述步骤,当基线信号变为单调函数或者常数时,停止循环,最终 X_t 可被分解为

$$X_t = LX_t + HX_t = [H(1+L) + L^2]X_t = \left(H \sum_{k=0}^{p-1} L^k + L^p \right) X_t = H_t^1 + H_t^2 + \dots + H_t^p + L_t^p \quad (3)$$

式中 H_t^k 为第 k 个固有旋转分量; L_t^p 为残余信号。

1.2 IITD 方法

由于 ITD 可能会使分解后的信号分量产生毛刺而失真,采用 Akima 插值来改进 ITD 方法,提出 IITD 算法,具体步骤如下:

1) 寻找信号 X_t 全部的局部极值点以及相应的时刻,采取和 ITD 方法一样的步骤 1) 和步骤 2) 来提取各基线控制点 L_k 。

2) 针对时间序列信号采用镜像对称延拓法去处理其端点,获得左右两端极值点 (τ_0, X_0) ,

(τ_{M+1}, X_{M+1}) , 令 k 分别为 0 和 $M-1$, 按照式(1)和式(2)获得 L_1 与 L_m 的值。然后所有的 L_k 用 Akima 插值函数来拟合可得到基线信号 $L_1(t)$ 。

3) 用原信号减去基线信号能够获得 $h_1(t)$, 即

$$h_1(t) = X_t - L_1(t) \tag{4}$$

如果基线 $L_{k+1} \neq 0$, 则 $h_1(t)$ 作为一个固有旋转分量, 即 $h_1(t) = P_1$, 如果基线 $L_{k+1} = 0$, 则把 $h_1(t)$ 作为原始信号重复步骤 1) 至步骤 2), 循环 k 次, 直到 $h_{1k}(t) = P_1$ 。然后, 将 P_1 从原信号中分离出来获得新信号 $r_1(t)$ 。

4) 再把 $r_1(t)$ 当作给定信号重复步骤 1) 至步骤 3), 获取原信号 X_t 的第 2 个 PR 分量 P_2 , 重复循环 $n-1$ 次, 获取 X_t 的第 n 个 PR 分量 P_n , 直到 $r_n(t)$ 为一单调函数或常数为止, 最终原信号 X_t 为 n 个 PR 分量 P_n 和一个残余项 $r_n(t)$ 之和, 即

$$X_t = \sum_p^n P_p + r_n(t) \tag{5}$$

1.3 仿真分析

建立下式所示的仿真信号, 比较 IITD、ITD、EMD 这 3 种方法的分解效果

$$\begin{cases} x_1(t) = [1 + 0.5\cos(10\pi t)] \cdot \sin[100\pi t + 2\sin(16\pi t)] \\ x_2(t) = \cos(30\pi t) \\ x(t) = x_1(t) + x_2(t), \quad t \in [0, 1] \end{cases} \tag{6}$$

该信号由一个余弦函数和一个调幅-调频分量构成, 时域波形如图 1。对该仿真信号分别进行 IITD、ITD 和 EMD 分解, 其分解结果如图 2、图 3 和图 4 所示。




图 1 信号 $x(t)$ 的时域波形

Fig. 1 Time domain waveform of the signal $x(t)$

由图 2、图 3 和图 4 可知: ITD 分解得到的第 2 个分量出现了变形和明显的端点效应现象, 而 EMD 和 IITD 分解得到的分量比较光滑; 其次从趋势项 r 可以看出 ITD 方法分解的拟合误差也比较大; 最后, ITD 和 IITD 分解得到两个分量, 第 1 阶分量基本与仿真信号中的 $x_1(t)$ 相吻合, 第 2 阶分量基本与仿真信号中的 $x_2(t)$ 相一致, 可以




图 2 信号 $x(t)$ 经 IITD 分解的结果

Fig. 2 Results of the signal $x(t)$ obtained by IITD




图 3 信号 $x(t)$ 经 ITD 分解的结果

Fig. 3 Results of the signal $x(t)$ obtained by ITD




图 4 信号 $x(t)$ 经 EMD 分解的结果

Fig. 4 Results of the signal $x(t)$ obtained by EMD

准确地体现信号的频率组成成分, 而 EMD 的前两阶分量虽然也可以表示仿真信号中的 $x_1(t)$ 、 $x_2(t)$ 成分, 但 EMD 分解的 IMF 分量中还出现了 $c_3 \sim c_5$ 等 3 阶虚假分量, 且产生了模态混叠现象, 由此可以看出 EMD 的分解误差比较大。基于上述比较, 可初步认定, IITD 方法使用 Akima 插值来提取基线, 可以更准确地分解原始信号, 同时能够克服 EMD 方法的模态混叠与产生虚假分量的

缺陷,以及 ITD 方法利用线性变换计算基线信号时带来的波形失真的缺陷。

2 近似熵

近似熵是 Pincus 在 1991 年提出一种用非负数衡量时间序列复杂度的方法,若时间序列越复杂,其近似熵值越大^[11-12]。滚动轴承的振动信号通常受机械结构变形、环境噪声、速度突变等因素影响,表现出复杂的非线性、非平稳特性。因此,近似熵可以衡量滚动轴承振动信号的复杂度。

设原始数据时间序列, $x(1), x(2), \dots, x(N)$ 共 N 个数据点。预先给定维数 m 和相似容限 r , 进而计算近似熵:

1) 将 $\{x(i)\}$ 按顺序构成一组 m 维矢量 $\mathbf{X}(i)$
 $\mathbf{X}(i) = [x(i), x(i+1), \dots, x(i+m-1)]$ (7)
式中 $i=1, 2, \dots, N-m+1$ 。

2) 定义两矢量之间的距离 $d[\mathbf{X}(i), \mathbf{X}(j)]$ 即
$$d[\mathbf{X}(i), \mathbf{X}(j)] = \max_{k=0, \dots, m-1} \{ |x(i+k) - x(j+k)| \}$$
 (8)

3) 给定相似容限 r 的阈值, 统计 $d[\mathbf{X}(i), \mathbf{X}(j)] \leq r$ 的数目 N_{um} , 以及此数目与总的矢量个数 $N-m+1$ 的比值, 记为 $C_i^m(r)$, 即

$$C_i^m(r) = \frac{N_{\text{um}}}{N-m+1} \quad (9)$$

式中 $C_i^m(r)$ 表示以矢量 $\mathbf{X}(i)$ 为中心, 矢量 $\mathbf{X}(j)$ 与 $\mathbf{X}(i)$ 的距离 $d[\mathbf{X}(i), \mathbf{X}(j)] \leq r$ 的概率。

4) 求所有 i 对应的 $\ln C_i^m(r)$ 的平均值 $\Phi^m(r)$
$$\Phi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \ln C_i^m(r)$$
 (10)
5) 取维数 $m+1$, 重复上述步骤, 得 $\Phi^{m+1}(r)$ 。
6) 近似熵的估计值为

$$ApEn(m, r, N) = \Phi^m(r) - \Phi^{m+1}(r) \quad (11)$$

由上述公式知, 近似熵值与 m, r 以及 N 的大小有关。Pincus^[12] 提出, 当 $m=2, r=0.1 \sim 0.25\sigma$ (σ 为原始数据的标准差) 时, 近似熵值具有较为合理的统计特性, 且此时对 N 的依赖最小, 因此, 该文 $r=0.25\sigma$ 。

3 模糊 C 均值聚类

模糊 C 均值聚类算法理论严谨, 聚类效果较好, 已在机械领域成功应用^[3, 5, 13], 是基于目标函数的众多聚类算法中最经典的一种。它是通过优化目标函数得到每个样本点对所有类中心的隶属度, 从而决定样本点的类属, 已达到自动将具有类似特征的数据样本聚为一类的目的^[13-14]。

已知数据样本集合 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ 的模糊分类矩阵 $\mathbf{A} = [a_{ij}]_{c \times n}$ 和聚类中心 $\mathbf{C} = [c_1, c_2, \dots, c_c]^T$, 其中 a_{ij} 为数据点 x_j 相对聚类中心 c_i 的隶属度, 且 a_{ij} 满足 $a_{ij} \in [0, 1], \sum_{i=1}^c a_{ij} = 1$

和 $\sum_{j=1}^n a_{ij} > 1, 0 \leq i \leq c, 1 \leq j \leq n$ 。FCM 算法实质上是不断更新聚类中心 $\mathbf{C}$ 和隶属度矩阵 $\mathbf{A}$ 使目标函数收敛的迭代过程。

d_{ij} 为样本点 x_j 到聚类中心 c_i 的欧氏距离, 即

$$d_{ij} = \|x_j - c_i\| = (x_j - c_i)^T (x_j - c_i) \quad (12)$$

定义 FCM 的目标函数为

$$J(\mathbf{A}, \mathbf{C}) = \sum_{j=1}^n \sum_{i=1}^c a_{ij}^m d_{ij}^2 \quad (13)$$

式中 m 为加权指数, 通常取 $m=2$ 。其步骤如下:

1) 确定聚类中心个数 c , 迭代次数 $l=0$, 并且初始化分类矩阵 $\mathbf{A} = [a_{ij}]_{c \times n}$ 。

2) 计算隶属度矩阵 $\mathbf{A}$

$$a_{ij} = 1 / \sum_{i=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)} \quad (14)$$

3) 更新聚类中心

$$c_i = \sum_{j=1}^n a_{ij}^m x_j / \sum_{j=1}^n a_{ij}^m \quad (15)$$

取合适的范数 $\epsilon > 0$, 若满足 $\|\mathbf{A}^{l+1} - \mathbf{A}^l\| < \epsilon$ 则终止运算, 否则使 $l=l+1$, 重复上述步骤 2) 和步骤 3), 直至满足条件。

通常采用分类系数和平均模糊熵对聚类算法的效果进行评价。对于给定的聚类中心个数 c 和分类矩阵 $\mathbf{A}$, 分类系数和平均模糊熵定义为

$$F = \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c a_{ij}^2 \quad (16)$$

$$H = -\frac{1}{n} \sum_{j=1}^n \sum_{i=1}^c a_{ij} \ln a_{ij} \quad (17)$$

分类系数是表示聚类结果模糊程度的标准, 对于硬划分 $F=1$, 对于模糊划分 $F < 1$, 而一般来说, 划分越分明越好, 因此 F 越接近 1, 聚类效果越好; 平均模糊熵表示分类的不确定性, 对于硬划分 $H=0$, 对于模糊划分 $H > 0$, 而一般来说, 不确定性越小越好, 因此 H 越接近 0, 聚类效果越好^[15]。

4 实验分析

实验所用的滚动轴承振动信号的数据来源于美国凯斯西储大学电气工程实验室的滚动轴承故障模拟试验台的轴承数据, 测试滚动轴承的型号为 6205-2RS SKF, 通过人工电火花技术将轴承加工成单点故障, 并使用加速度传感器在垂直固定

在感应电动机输出端支撑轴承上方的外壳上进行数据采集。

4.1 不同类型故障分类

不同类型故障分类的实验数据选用的是在采样频率为 12kHz,轴承转速为 1797r/min,故障直径为 0.1778mm 状态下的数据,故障类型包括正常、内圈故障、外圈故障以及滚动体故障。

以滚动轴承内圈信号为例,采用 IITD 方法分解信号为 6 个 PR 分量 $P_1 \sim P_6$ 和一个剩余分量 r ,其分解结果如图 5 所示。为了得到可以表征原始信号关键信息的分量,采用互信息法来确定。文献[16]的研究结果显示,互信息法比相关系数法[17]更加准确。同理,用 ITD、EMD 把内圈故障信号分解为多阶分量。计算 3 种方法分解后的各分量与原信号的互信息 M_k ,并对其做归一化处理。结果如表 1 所示。




图 5 内圈故障信号 PR 分量

Fig. 5 PR components of the outer ring fault signal

表 1 分量与原信号的互信息

Table 1 Mutual information between each mode and the original signal

算法	互信息					
	M_1	M_2	M_3	M_4	M_5	M_6
EMD	1.0893	0.1188	0.0425	0.0115	0.0069	4.77×10^{-5}
ITD	1.1796	0.1711	0.0430	0.0105	0.0035	1.92×10^{-5}
IITD	0.6791	0.1100	0.0512	0.0026	0.0155	0.0110

从表 1 中可知,EMD、ITD 和 IITD 分解后的故障信号的前 3 个分量与原信号的互信息均大于阈值 0.02[16],且大于其他分量。因此,前 3 个分量就是充分表征原始信号特征量的真实分量。

为保证数据充分,对 4 种类型的故障信号连续取同一时期的 40 组数据样本,每个样本容量为 2048 个数据点,将前 20 组作为已知故障样本,后 20 组作为待识别样本,求取所有样本前 3 个 PR 分量的近似熵,最终得到 4 个 3×20 的已知故障样本的近似熵矩阵和 4 个 3×20 的待识别样本的近似熵矩阵。同时为说明近似熵可以作为聚类分析的依据,求取 4 种滚动轴承故障类型信号的 40 组数据样本的近似熵均值,结果如表 2 所示。

由表 2 可知,同种故障类型信号的 PR 分量 $P_1 \sim P_3$ 的近似熵值不同,即 3 个 PR 分量的复杂程度不同,并且 4 种不同故障类型信号的各阶 PR 分量的近似熵值也不相同,表明各故障类型信号的复杂度也不同。因此,各 PR 分量的近似熵值可作为聚类分析的特征向量。

表 2 前 3 个 PR 分量的近似熵

Table 2 Approximate entropy of first three PR

信号类型	近似熵		
	P_1	P_2	P_3
正常信号	0.2397	0.3773	0.4256
内圈故障	1.1640	1.1134	0.7453
外圈故障	0.6816	1.1094	0.6750
滚动体故障	0.4117	0.6596	0.6305

根据 4 种故障类型信号,设置聚类中心数为 $c=4$,容差为 $\epsilon=10^{-4}$,经迭代计算并不断更新聚类中心,直到收敛为止。使用 4 个已知故障样本的近似熵矩阵来构成一个 3×80 的特征向量矩阵,输入到 FCM 中形成 4 个聚类中心,然后对 4 组待识别样本聚类识别。结果如图 6 所示,图 6(a)为三维空间分布图,图 6(b)是图 6(a)在 $P_1 \sim P_2$ 平面上的二维聚类分布图。由于 3 个视角的二维聚类分布图,具有相同聚类识别效果,因此该

文只取一个视角的二维聚类分布图进行分析。图中明显出现了 4 个聚类簇,而且不同故障类型的待识别样本紧密分布在各自的聚类中心周围,各聚类中心之间有明显的空间距离,无明显交叉混叠现象出现。




图 6 IITD 近似熵的聚类图

Fig. 6 Clustering drawing of IITD approximate entropy

根据同种故障信号样本具有相似度高的特点,4 种故障类型信号的待识别样本经 FCM 分类后,聚集在不同的聚类中心周围,且分布比较紧凑。因此,在滚动轴承故障诊断中,基于 IITD 的模糊聚类方法是具有极高的识别效率和良好分类效果。

同理,取上述的 20 组已知故障样本和 20 组待识别的故障样本,采用 EMD 和 ITD 分解,同样通过互信息分析,求得前 3 个分量为有效分量,把这 3 个分量的近似熵作为特征向量输入到 FCM 分类器,其分类结果如图 7 和图 8 所示。

从图 7 和图 8 可知,4 种故障类型的数据也可以通过基于 EMD、ITD 近似熵的模糊聚类方法进行识别分类。集中对比图 6、图 7 和图 8,可以看出,它们的聚类中心位置和待识别样本分布在聚类中心的周围的紧密程度都是不同的,这是由于利用不同的自适应分解方法对原始信号进行分解的结果,由此得到分量所包含原始信号的有效成分存在区别。因此,经 FCM 处理后的数据样本的聚类中心的分布状况和位置也存在差异。

为了得出更有效的提取方法,采用分类系数 F 和平均模糊熵 H 来对上述 3 种方法的聚类效果进行评价,结果如表 3 所示。




图 7 EMD 近似熵的聚类图

Fig. 7 Clustering drawing of EMD approximate entropy




图 8 ITD 近似熵的聚类图

Fig. 8 Clustering drawing of ITD approximate entropy

表 3 聚类效果检验

Table 3 Experimental result of clustering quality

算法	聚类指标	
	分类系数 F	平均模糊熵 H
EMD	0.909 2	0.213 2
ITD	0.944 3	0.144 2
IITD	0.967 9	0.092 2

从表 3 中可以明显的看出,基于 IITD 的模糊聚类方法的分类系数 F 更接近 1,平均模糊熵 H 更接近 0,从而证明,本文算法比基于 EMD、ITD 的模糊聚类方法的聚类效果要更好。这是因为 EMD 方法使用三次样条插值拟合上下包络,在边界容易产生拟合误差,同时 EMD 递归模式会将拟合误差不断传播和扩大;ITD 方法提取基线信号时,采用的是线性拟合,使分解得到的 PR 分量出现失真,同时在一定程度上增大了拟合误差,降低了诊断可靠性;而 IITD 方法首先使用 ITD 中的线性变换去提取基线控制点,然后再利用 Akima 插值法去连接所有基线控制点以获得相应的基线信号,这样减少了拟合误差,因此,各 PR 分量更能有效表征原始信号,从而使得基于 IITD 近似熵方法的聚类效果更优于基于 EMD、ITD 近似熵方法的聚类效果。

4.2 不同损伤程度故障诊断

为深入验证本文诊断方法,取轴承内圈不同损伤程度的振动信号进行分析:数据包括内圈的正常、轻微损伤和严重损伤信号,其中轻微和严重的单点故障直径分别为 0.1778mm 和 0.5344mm。

对于不同损伤程度的内圈故障信号分别取 40 组数据,前 20 组作为已知故障样本,后 20 组作为待识别样本,依据上述方法步骤,对此 3 类故障信号进行 IITD、EMD 和 ITD 分解,同样采用互信息分析,选取前 3 个分量进行近似熵特征信息提取。两种不同分解方法得到 2 个 3×60 的已知故障样本特征矩阵和 2 个 3×60 的待识别故障样本特征矩阵,并进行 FCM 聚类分析和识别,结果如图 9~图 11 所示。




图 9 IITD 近似熵的聚类图(不同损伤程度)
Fig. 9 Clustering drawing of IITD approximate entropy (different damage levels)

从图 9~图 11 可知,上述两种方法对 3 种不同损伤程度的滚动轴承故障信号均实现了很好的聚类效果。3 张图相比较可知,基于 IITD 模糊聚




图 10 EMD 近似熵的聚类图(不同损伤程度)
Fig. 10 Clustering drawing of EMD approximate entropy (different damage levels)




图 11 ITD 近似熵的聚类图(不同损伤程度)
Fig. 11 Clustering drawing of ITD approximate entropy (different damage levels)

类方法的数据样本在其聚类中心附近分布地更为紧凑。因此,定性分析可知,基于 IITD 的模糊聚类方法分类效果更佳。以定量的角度分析,如表 4 所示,基于 IITD 的聚类方法的分类系数比基于 EMD、ITD 的聚类方法的大;而平均模糊熵比基于 EMD、ITD 的聚类方法的小。其聚类效果检验指标同样验证该方法的精确性。

表 4 聚类效果检验(不同损伤程度)
Table 4 Experimental result of clustering quality (different damage levels)

算法	聚类指标	
	分类系数 F	平均模糊熵 H
EMD	0.9547	0.1057
ITD	0.9715	0.0736
IITD	0.9809	0.0539

5 结 论

IITD 是在固有时间尺度分解的基础上进行改进的一种自适应的信号处理方法,它不仅克服了 ITD 的缺点使所得分量具有好的光滑性,同时还保留了 ITD 的优点。通过 IITD 分解得到 PR

分量,并计算其近似熵作为特征向量,能够实现原始信号特征信息准确提取的目的,为滚动轴承的故障的模式识别提供依据。

实验以滚动轴承故障信号为例,分别采用基于 IITD、EMD 和 ITD 近似熵与模糊 C 均值聚类相结合的分析手段对故障信号进行识别分类,并进行对比验证。结果表明:3 种方法均可识别不同的故障信号,且结果一致,但基于 IITD 近似熵的模糊 C 均值聚类方法的准确度较高,且更能有效的识别故障特征并进行精确分类,可进一步推广应用到工程实践中。

参考文献:

- [1] 郑红,周雷,杨浩. 基于小波包分析与多核学习的滚动轴承故障诊断[J]. 航空动力学报,2015,30(12):3035-3042.
ZHENG Hong, ZHOU Lei, YANG Hao. Roller bearing fault diagnosis based on wavelet packet analysis and multi kernel learning[J]. Journal of Aerospace Power, 2015, 30(12):3035-3042. (in Chinese)
- [2] 向丹,岑建. 基于 EMD 熵特征融合的滚动轴承故障诊断方法[J]. 航空动力学报,2015,30(5):1149-1155.
XIANG Dan, CEN Jian. Method of roller bearing fault diagnosis based on feature fusion of EMD entropy[J]. Journal of Aerospace Power, 2015, 30(5):1149-1155. (in Chinese)
- [3] 王军辉,贾嵘,谭泊. 基于 EEMD 和模糊 C 均值聚类的风电机组齿轮箱故障诊断[J]. 太阳能学报,2015,36(2):319-324.
WANG Junhui, JIA Rong, TAN Bo. Fault diagnosis of windturbine's gearbox based on EEMD and fuzzy C means clustering[J]. Acta Energiæ Solaris Sinica, 2015, 36(2):319-324. (in Chinese)
- [4] 杨宇,王欢欢,程军圣,等. 基于 LMD 的包络谱特征值在滚动轴承故障诊断中的应用[J]. 航空动力学报,2012,27(5):1153-1158.
YANG Yu, WANG Huanhuan, CHENG Junsheng, et al. Application of envelope spectrum characteristics method based on LMD to roller bearing fault diagnosis[J]. Journal of Aerospace Power, 2012, 27(5):1153-1158. (in Chinese)
- [5] 段礼祥,张来斌,岳晶晶. 基于 ITD 和模糊聚类的齿轮箱故障诊断方法[J]. 中国石油大学学报(自然科学版),2013,37(4):133-139.
DUAN Lixiang, ZHANG Laibin, YUE Jingjing. Fault diagnosis method of gearbox based on intrinsic time-scale decomposition and fuzzy clustering[J]. Journal of China University of Petroleum (Edition of Natural Science), 2013, 37(4):133-139. (in Chinese)
- [6] HUANG N E, SHEN Z, LONG S R, et al. A new view of nonlinear waves: the Hilbert spectrum[J]. Annual Review of Fluid Mechanics, 1999, 31(1):417-457.
- [7] YANG Y, CHENG J S, ZHANG K. An ensemble local means decomposition method and its application to local rub-impact fault diagnosis of the rotor systems[J]. Measurement, 2012, 45(3):561-570.
- [8] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1):1-41.
- [9] FREI M G, OSORTO I. Intrinsic time-scale decomposition: time-frequency-energy analysis and realtime filtering of non-stationary signals[J]. Proceeding of the Royal Society A, 2007, 463(2078):321-342.
- [10] 向玲,鄢小安. 基于小波包的 EITD 风力发电机组齿轮箱故障诊断[J]. 动力工程学报,2015,35(3):205-212.
XIANG Ling, YAN Xiaolan. Fault diagnosis of windturbine gearbox based on EITD-WPT method[J]. Journal of Chinese Society of Power Engineering, 2015, 35(3):205-212. (in Chinese)
- [11] 胥永刚,何正嘉. 分形维数和近似熵用于度量信号复杂性的比较研究[J]. 振动与冲击,2009,28(5):13-16.
XU Yonggang, HE Zhengjia. Research on comparison between approximate entropy and fractal dimension for complexity measure of signals[J]. Journal of Vibration and Shock, 2009, 28(5):13-16. (in Chinese)
- [12] PINCUS S M. Approximate entropy as a measure of system complexity[J]. Proceeding of the National Academy Sciences of the United States of America, 1991, 88(6):2297-2301.
- [13] 刘长良,武英杰,甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报,2015,35(13):3358-3365.
LIU Changliang, WU Yingjie, ZHEN Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of the CSEE, 2015, 35(13):3358-3365. (in Chinese)
- [14] PAL N R, BEZDEK J C. On cluster validity for the fuzzy C-means model[J]. IEEE Transactions on Fuzzy Systems, 1995, 3(3):370-379.
- [15] BEZDEK J C. Cluster validity with fuzzy sets[J]. Journal of Cybernetics, 1974, 3(3):58-72.
- [16] 胡爱军. Hilbert-Huang 变换在旋转机械振动信号分析中的应用研究[D]. 河北保定:华北电力大学,2008.
HU Aijun. Research on the application of Hilbert-Huang transform in vibration signal analysis of rotating machinery [D]. Baoding Hebei: North China Electric Power University, 2008. (in Chinese)
- [17] PENG Z K, TSEP W, CHU F L. A comparison study of improved Hilbert-Huang transform and wavelet transform: application to fault diagnosis for rolling bearing[J]. Mechanical Systems and Signal Processing, 2005, 19(5):974-988.