

频域特征驱动的车辆旋转部件灰色故障诊断*

苏舟¹, 石娟娟¹, 关云辉², 张晶², 黄伟国¹, 沈长青¹, 朱忠奎¹

(1. 苏州大学轨道交通学院 苏州, 215131)

(2. 中车戚墅堰机车车辆工艺研究所有限公司 常州, 213011)

摘要 根据不同故障引起的振动信号频域特征各异的特点, 首先, 运用调 Q 小波变换(tunable Q -factor wavelet transform, 简称TQWT)的频率响应对车辆旋转部件振动信号或其包络信号进行分析, 构建以信号在不同频段各子带能量占比为元素的特征向量; 其次, 针对灰色接近关联度在处理2组相交的序列时存在的两序列变化趋势不同、原始累差小而导致关联度过大的问题, 提出了灰色绝对接近关联度模型; 最后, 在所构建的频域特征向量驱动下, 计算其与标准模式的灰色绝对接近关联度, 对车辆关键旋转部件故障状态进行识别。利用所提方法对列车轮对轴承和汽车变速器齿轮箱不同运行状态的振动信号进行分析, 结果表明, 所提方法能够准确识别车辆旋转部件的运行状态和故障类型, 通过对比分析验证了该方法的优越性。

关键词 轴承; 齿轮箱; 故障诊断; 故障辨识; 能量分布
中图分类号 TH165.3; TH17

引言

车辆在交通运输和工业生产中发挥着越来越重要的作用, 其关键旋转部件的故障诊断对车辆运行的可靠性和安全性至关重要^[1-4]。机械故障诊断本质上是模式识别问题。常用的故障模式识别方法有模糊理论(fuzzy theory, 简称FT)、支持向量机(support vector machine, 简称SVM)、深度学习(deep learning, 简称DL)及灰色理论等。FT识别方法可以对故障进行快速实时自动识别, 识别过程中不需要人工干预, 但是存在模糊诊断矩阵难以确定、利用信息单一及学习能力差等问题^[5]。基于SVM的智能故障诊断方法可以解决小样本的识别问题, 同时可以解决高维及非线性问题, 但其参数调节和核函数的选择对分类结果与精度产生较大影响^[6]。近年来, 基于DL的故障诊断方法成为机械故障诊断的研究热点之一, 其具有强大的学习能力, 在大数据驱动下可以处理复杂识别任务, 且覆盖范围广、适应性好, 然而DL仍存在需要海量数据、对计算能力要求高及模型设计复杂等不足^[7]。

与上述模式识别方法相比, 基于灰色理论的模式识别方法对样本数量没有太多要求, 不要求数据具有典型的分布规律, 而且算法更简单, 计算速度更快, 对小样本模式识别问题具有良好的分类效果, 已得

到广泛应用^[7]。沈路等^[8]对采集到的振动信号进行形态滤波去除噪声干扰, 以故障频率的归一化幅值为元素构建特征向量, 采用灰色邓氏关联度来实现滚动轴承的故障类型识别, 虽然识别效果较好, 但仅限信噪比较高的信号。王录雁等^[9]采用经验模态分解(empirical mode decomposition, 简称EMD)方法, 结合灰色关联模型建立固有模态函数(intrinsic mode function, 简称IMF)能量分布与轴承健康状态的对应关系, 将灰色接近关联度模型与分段斜率关联度模型相结合, 提出了基于接近性和相似性的灰色综合关联度诊断模型, 但是该关联度数值较小, 难以反映真实的相近程度。冉钧等^[10]利用故障信号特征频率的幅值作为特征向量, 通过计算频域振幅灰色关联度实现转子故障模式辨识, 但是该方法受信号噪声的影响较大。张文斌等^[11]基于集合经验模态分解构建能量分布, 采用灰色相似关联度对齿轮系统进行故障诊断, 但是关联度区分较小, 易造成误判。因此, 在充分利用灰色关联度模型算法高效的同时, 也需进一步提高其识别准确性。

在模式识别之前往往要对采集到的振动信号进行处理, 提取出反映机械设备运行状态的有用信息^[12]。当机械设备零部件发生故障时, 振动信号各频带的能量分布会发生改变, 其中包含了丰富的故障信息, 因此可以基于能量分布进行特征信息的提

* 国家自然科学基金资助项目(51605319, 52075353); 江苏省苏州市前瞻性应用研究资助项目(SYG202012)

收稿日期: 2021-06-08; 修回日期: 2021-08-13

取^[13]。为提取信号在频域上的能量分布及特征信息,首先需要将信号进行分解。由于车辆关键旋转部件如轴承或齿轮,其故障特征频率及频域上与故障相关的能量分布主要体现在低频部分,故只需对低频部分有足够高的分辨率就能满足模式识别对频域故障特征信息提取的要求。TQWT是一种能够将高频和低频部分进行划分的信号处理方法,可精细地刻画出信号低频部分的能量分布,其频率响应信号的频带具有从粗到细的划分作用,且可通过调整相关参数实现对频带划分分辨率的调整。

笔者提出一种信号频域特征驱动的灰色故障诊断方法,运用TQWT对振动信号进行频域响应分析,并以能量分布为元素构建特征向量,将其输入到提出的灰色绝对接近关联度模型,通过比较待识别样本与标准故障状态样本的输出,对车辆关键旋转部件故障状态进行识别。

1 车辆旋转部件故障频域特征

1.1 滚动轴承振动响应频域特征

在轴承使用过程中,可以通过分析损伤失效产生的振动响应获取故障特征信息。当轴承发生局部缺陷时,缺陷反复碰撞其他元件而产生低频振动成分,此频率称为故障特征频率。该频率仅与转速及其几何尺寸有关,其故障特征频率和故障类型一一对应^[14]。

不同故障类型的轴承振动信号包络频谱图如图1所示。可以看出,不同故障类型的轴承具有各异的频域分布特征,因此轴承振动信号包络的频域响应特征蕴含了轴承健康状态及故障类型信息。

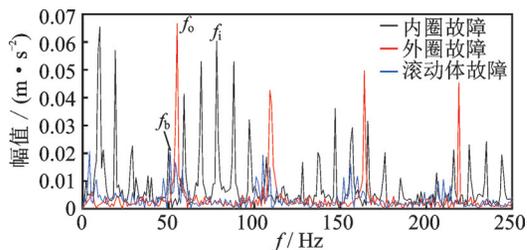


图1 不同故障类型的轴承振动信号包络频谱图
Fig.1 Envelope spectrum of bearings with different fault types

1.2 齿轮振动响应频域特征

1.2.1 正常状态齿轮振动信号的频域响应特征

正常状态下,齿轮在啮合点处的动力学方程^[15]为

$$M\ddot{x}(t) + C\dot{x}(t) + K_0x(t) = -Ek_1(t) - x(t)k_1(t) \quad (1)$$

其中: M 为当量质量; C 为轮齿啮合阻尼; E 为轮齿受载后的静弹性形变; $K_0, k_1(t)$ 分别为啮合静刚度和啮合动刚度; $x(t)$ 为轮齿在啮合线上的相对位移。

式(1)等号左边为2阶线性振动系统,右边可等效为系统激励,分为2部分:①线性激励,是由齿轮受载后的啮合时变刚度 $k_1(t)$ 和静弹性形变 E 共同激起的弹性激励力 $Ek_1(t)$;②非线性激励,是由相对位移响应 $x(t)$ 的负反馈与啮合时变刚度 $k_1(t)$ 作用产生的激励力 $x(t)k_1(t)$ 。不论是线性激励还是非线性激励,均产生啮合频率及其高次倍频的频率成分。各阶次幅值由于受各阶次阵型等因素干扰,失去了逐次递减的规律性。不同健康状态齿轮振动响应频率特征如图2所示。

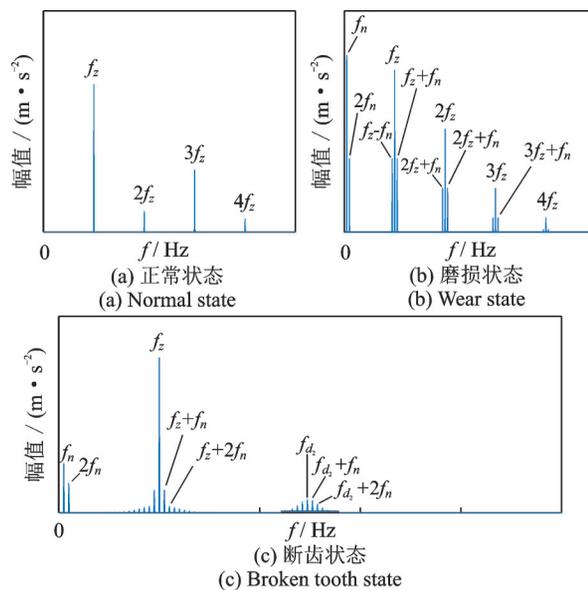


图2 不同健康状态齿轮振动响应频率特征
Fig.2 Frequency characteristics of gear vibration response under different health conditions

1.2.2 磨损状态齿轮的频域响应特征

当齿轮发生磨损时,齿轮在啮合点处会产生位移激励,且其变化周期为转频。其动力学方程^[15]为

$$M\ddot{x}(t) + C\dot{x}(t) + K_0e(t) + e(t)k_1(t) - x(t)k_1(t) \quad (2)$$

其中: $e(t)$ 为位移误差函数。

式(2)等号左边为2阶线性振动系统,右边可等效为系统激励,由4部分组成:①弹性激励力 $Ek_1(t)$;②惯性激励力 $M\ddot{e}(t)$ 、阻尼激励力 $C\dot{e}(t)$ 和弹性力 $K_0e(t)$;③弹性力 $e(t)k_1(t)$;④振动位移响应负反馈与

啮合时变刚度 $k_1(t)$ 作用下产生的激励力 $x(t)k_1(t)$ 。

前3部分是线性激励。其中:第1部分引起的振动响应频率是啮合频率 f_z 及其倍频;第2部分引起损伤齿轮所在轴的转频 f_n 及其倍频;第3部分是啮合频率 f_z 及其倍频,两侧间隔为转频 f_n 及其倍频的调制边频带;第4部分为非线性激励引起的阶数更高的啮合频率 f_z 及其边频带。磨损状态齿轮的频域响应特征如图2(b)所示,可见幅值失去递减特征。磨损状态齿轮的频域响应较正常状态增加了转频调制边频带和转频及其倍频成分,且啮合频率及其倍频的幅值更大。

1.2.3 断齿状态齿轮的频域响应特征

对于断齿故障,可用仿真信号^[16]进行研究,即

$$x(t) = x_0(t) + x_1(t) + x_2(t) \quad (3)$$

其中: $x_0(t)$, $x_1(t)$ 和 $x_2(t)$ 分别为转频调制、稳态调制和冲击调制成分。

$$x_0(t) = \cos(2\pi f_n t) + 0.6\cos(4\pi f_n t + \pi/4) \quad (4)$$

$$x_1(t) = [3 + \cos(2\pi f_n t + \pi/3)] \cos(2\pi f_z t) \quad (5)$$

$$x_2(t) = \sum_{k=0}^9 h_1(t - kT) + \sum_{k=0}^9 h_2(t - kT) \quad (6)$$

其中: $h(t) = A \exp[-2\pi\zeta f_d(t - \tau)/\sqrt{1 - \zeta^2}]$, 为冲击响应。

由于轮齿折断引发的冲击型振动能量大,易激发固有频率,导致产生固有频率调制现象。与磨损状态相比,其边频带数量多、幅值大、分布宽,啮合频率及转频均出现更多次高阶谐波。参考文献[16]设定相应参数后,上述仿真信号的频域特征如图2(c)所示。齿轮的故障严重程度使得振动信号的频域特征产生变化,因此提出了基于频域特征的齿轮故障灰色诊断方法。

以上表明,不同健康状态下轴承和齿轮的振动信号包络在各个频段上的能量分布各异,因此可以根据振动信号本身或其包络在沿频率的能量分布对车辆旋转部件(齿轮和轴承)进行故障辨识。

2 信号频域特征驱动的灰色故障诊断算法

2.1 基于调 Q 小波变换的信号频域特征向量构建

振动信号或其包络的频域响应及频域特征包含了与车辆关键旋转部件健康状态相关的信息,准确揭示其频域特征、构建出可映射零部件健康状态的特征向量是该算法的关键。

调 Q 小波变换是一种从频域滤波角度设计的小波变换方法,其依赖一组包含分解和重构滤波器的双通道滤波器组,通过迭代运算,实现信号的分解与重构^[17]。双通道滤波器组如图3所示。其中: $H_0(\omega)$, $H_1(\omega)$ 分别为低通和高通滤波器的频率响应函数; α , β 分别为低通和高通尺度因子, $\alpha = 1 - \beta/r$, $\beta = 2/(Q + 1)$, 且满足 $0 < \alpha < 1$, $0 < \beta \leq 1$, $\alpha + \beta > 1$ 。

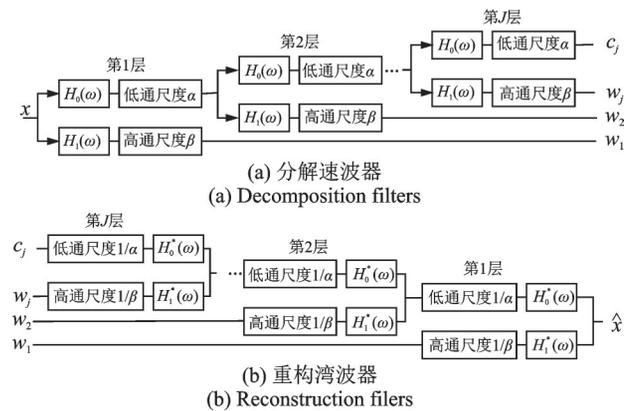


图3 双通道滤波器组

Fig.3 Two channels filters

给定品质因子 Q 和冗余因子 r , 可得到惟一频率响应, 第 j 个子带的频率响应范围为 $[(1 - \beta)\alpha^{j-1}\pi, \alpha^{j-1}\pi]$, 第 j 个子带的带宽和中心频率为

$$\begin{cases} BW_j = \frac{1}{2} \beta \alpha^{j-1} \pi \\ f_{cj} = \alpha^j \frac{2 - \beta}{4\alpha} f_s \end{cases} \quad (7)$$

其中: f_s 为采样频率。

由式(7)可知,子频带序数 j 越大,频率响应的带宽和中心频率越小。分解层数 J 并不能取无穷大,在给定 Q 和 r 时,最大分解层数 J_{\max} 为

$$J_{\max} = \left\lfloor \frac{\lg[N/4(Q + 1)]}{\lg[(Q + 1)/(Q + 1 - 2/r)]} \right\rfloor \quad (8)$$

其中: N 为信号长度; $\lfloor \cdot \rfloor$ 为向下取整符号。

Q 用来描述小波函数的振荡程度, r 用来表示频率响应的重叠程度^[18]。当 r 固定时, Q 的增大将使带宽变窄,有利于提高频率分辨率,但过大的 Q 会导致覆盖频率范围减小。当 Q 固定时, r 的增大将使各子带频率响应的带宽变窄,频率响应分辨率增大,而覆盖频率范围增加的影响较小,可以忽略不计,但过大的 r 会增加计算成本^[19]。图4,5分别给出了改变 Q 因子和改变 r 因子的调 Q 小波变换频率响

应。调Q小波变换相关参数的影响如表1所示,表中总结了各参数对各子带频率响应的带宽、覆盖频率范围和计算成本的影响。因此,应综合考虑多个因素,选择与目标函数匹配的Q值和r值。

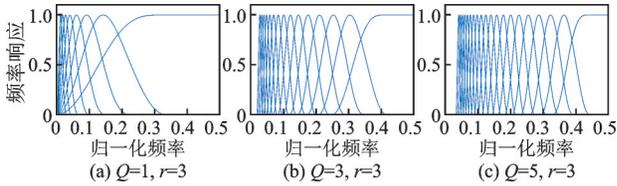


图4 改变Q因子的调Q小波变换频率响应

Fig.4 Frequency responses of TQWT with change of Q-factor

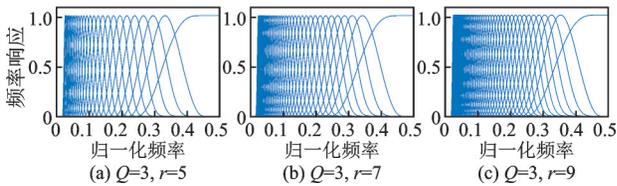


图5 改变r因子的调Q小波变换频率响应

Fig.5 Frequency responses of TQWT with change of r-factor

表1 调Q小波变换相关参数的影响

Tab.1 Effects of the parameters related to the TQWT

参数	各子带频率响应的带宽	覆盖频率范围	计算成本
Q	若Q增大则变小	若Q增大则变小	若Q增大则变大
r	若r增大则变小	若r增大则变大	若r增大则变大
J	无直接影响	若J增大则变大	若J增大则变大

确定好相关参数后,对信号采用调Q小波变换,计算各子带的能量 E_j ,再求出各子带能量与信号总能量的比值 T_j ,即

$$E_j = \int_{-\infty}^{+\infty} |\omega_j(t)|^2 dt \quad (9)$$

$$T_j = E_j / \sum_{j=1}^J E_j \quad (10)$$

其中: j 为子带序号, $j=1,2,\dots,J$; ω_j 为第 j 个子带的小波系数。

因此,以子带的能量分布为元素构建了反映零部件健康状态的信号频域特征向量 $T=[T_1, T_2, \dots, T_J]$ 。

2.2 灰色绝对接近关联度模型

灰色关联分析是灰色系统理论进行系统分析的重要方法,其基本思想是根据序列曲线几何形状的分析来度量系统各个序列之间的联系是否紧密,即几何形状越接近关联度越大,反之越小^[20]。

自灰色关联度模型^[21]提出之后,许多学者根据实际需要,对灰色关联度进行了构造和改进,如相似关联度、接近关联度等,其中接近关联度常用于模式识别。灰色接近关联度定义如下:设 i, j 为序列标号,系统行为序列 $X_i=(x_i(1), x_i(2), \dots, x_i(n))$, $X_j=(x_j(1), x_j(2), \dots, x_j(n))$,令

$$S_i - S_j = \int_1^n (X_i - X_j) dt \quad (11)$$

则称 $(S_i - S_j)$ 为 X_i 与 X_j 的原始累差。

若 X_i 与 X_j 长度相同,则其灰色接近关联度为

$$\rho_{ij} = 1 / (1 + |S_i - S_j|) \quad (12)$$

ρ_{ij} 用于测度序列 X_i 与 X_j 在空间位置的接近程度。

根据文献[22],当 X_i 与 X_j 重合,或 X_i 围绕 X_j 摆动,且 X_i 位于 X_j 之上部分的面积与 X_i 位于 X_j 之下部分的面积相等时, $\rho_{ij}=1$ 。因此,当2组序列构成的折线相交时,其变化趋势可能相差较大,但原始累差为两折线上方与下方填充区域面积的差值,得到的数值可能偏小。传统灰色接近关联度模型识别错误分析如图6所示。由图可以看出,样本虽然与滚子故障折线的整体变化趋势更为接近,但是与外圈故障折线的原始累差很小,导致关联度过大,易造成误判。针对此不足,构造了灰色绝对接近关联度模型。

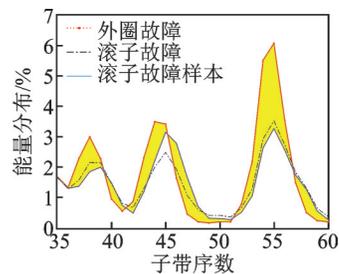


图6 传统灰色接近关联度模型识别错误分析

Fig.6 The error analysis of identification using grey close relation degree model

对于系统行为序列 X_i 和 X_j ,令

$$\Delta X_{ij} = \sum_{k=1}^n |X_i(k) - X_j(k)| \quad (13)$$

其中: $k=1,2,\dots,n$ 。

灰色绝对接近关联度 ρ_{ij} 为

$$\rho_{ij} = 1 / (1 + \Delta X_{ij}) \quad (14)$$

灰色绝对接近关联度模型满足灰色关联公理,并具有以下性质:

1) 由式(13)可知 $\Delta X_{ij} \geq 0$,代入式(14)可得 $0 < \rho_{ij} \leq 1$;

- 2) 当 $i=j$ 时, $\Delta X_{ii}=0$, 则 $\rho_{ii}=1$;
- 3) 由式(13)可知 $\Delta X_{ij}=\Delta X_{ji}$, 则 $\rho_{ij}=\rho_{ji}$;
- 4) ρ_{ij} 不仅与 X_i 及 X_j 的几何形状有关, 还与其空间位置有关, 即平移会导致此关联度数值改变;
- 5) X_i 与 X_j 越接近, ρ_{ij} 越大, 反之越小。

因此, 可以利用灰色绝对关联度计算待识别样本与各种状态标准模式的关联程度, 从而实现分类识别。

2.3 频域特征向量驱动的灰色故障诊断方法

将蕴含车辆旋转部件健康状态相关信息的频域特征向量输入到所提灰色绝对接近关联度模型中, 通过计算待识别样本与标准模式间的绝对接近关联度对旋转部件健康状态进行识别。频域特征向量驱动的灰色故障诊断算法如图7所示, 其具体步骤如下:

- 1) 在车辆旋转部件不同运行状态下多次采样, 得到相关振动信号;
- 2) 选取合适的调Q小波参数, 对采集的振动信号或其包络进行频域响应分析, 获取各频段下的子

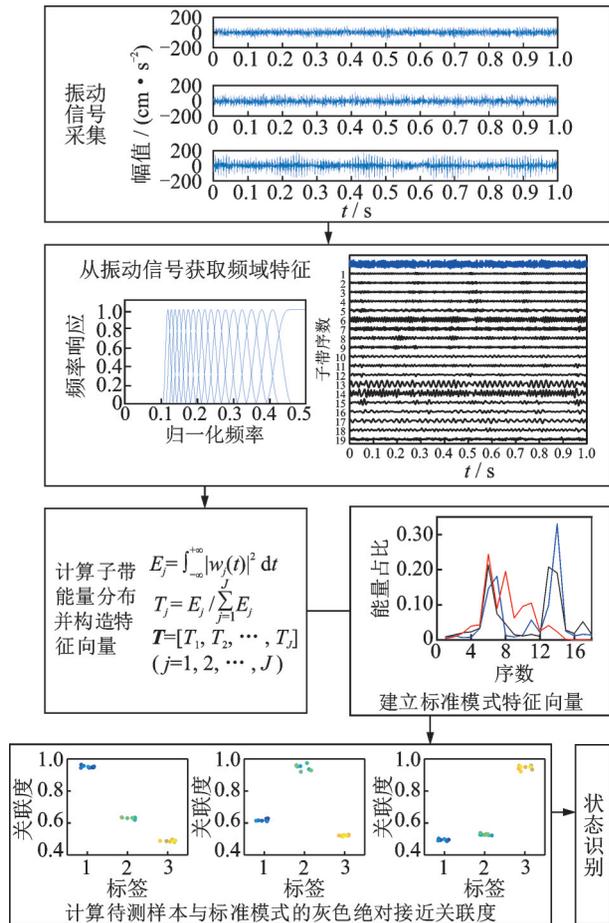


图7 频域特征向量驱动的灰色故障诊断算法示意图
Fig.7 Schematic diagram of grey fault diagnosis algorithm driven by signal frequency domain features

带信息;

- 3) 计算各子带的能量占比, 并以此为元素构造特征向量 $T=[T_1, T_2, \dots, T_J]$;
- 4) 每种状态任取5个样本的能量占比分布均值作为标准模式;
- 5) 计算待识别样本与各标准模式之间的绝对接近关联度, 与待识别样本关联度最大的模式即为待识别样本所处的运行状态。

3 试验验证

3.1 列车轮对轴承故障

为了验证本研究提出的方法在轴承故障识别中的有效性, 在轴承试验台上分别对正常、内圈故障、外圈故障和滚动体故障4种工况下的列车轮对轴承进行了试验分析。列车轮对轴承试验台如图8所示, 轴承的内圈与主轴连接, 由驱动电机驱动, 外圈固定并连接径向载荷加载机构。通过线切割方法分别在轴承内圈、外圈和滚动体上加工宽度约为0.18 mm、深度约为1 mm的沟槽, 轴承型号为NJ(P)3226X1。试验时转频为10 Hz, 经理论计算得到内圈故障特征频率为81.8 Hz, 外圈故障特征频率为58.2 Hz, 滚动体故障特征频率为57.7 Hz。

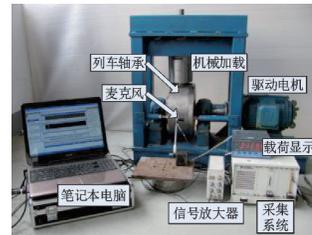


图8 列车轮对轴承试验台
Fig.8 Test rig for train bearing

对列车轮对上述4种工况分别采样, 各得30组数据, 其中随机选取5组用于构建标准模式, 其余25组用于测试。根据试验信号的特征, 分别对不同健康状态的包络信号进行参数为 $Q=5, r=3, J=45$ 的调Q小波变换, 计算各子带能量占比, 构造标准模式特征向量。轴承4种工况下标准模式能量分布如图9所示。可以看出, 轴承不同运行状态所对应的能量分布有明显区别, 且轴承故障特征频率正好处在能量分布最高的子带所对应的频带上。这符合故障振动信号的特征, 有利于辨识故障类型。

对100个待识别样本进行状态识别, 采用灰色绝对接近关联度的轴承待测样本识别结果如图10所示。其中, 标签1~4分别表示正常状态、内圈故

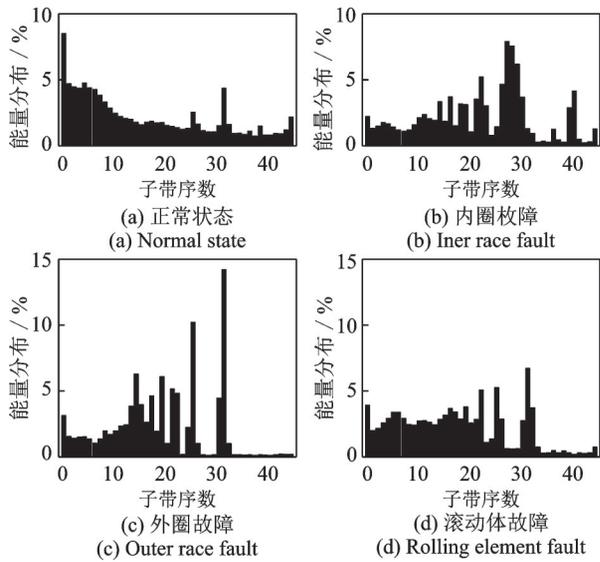


图 9 轴承 4 种工况下标准模式能量分布图

Fig.9 Energy distribution diagram of standard mode under four working conditions of bearing

障、外圈故障和滚动体故障。由图 10(a)可以看出,正常状态样本与其标准模式关联度均在 0.9 左右,而与其他状态关联度仅为 0.5~0.7。由图 10(b)可以看出,内圈故障样本与其标准模式关联度明显高于其他状态标准模式关联度。从识别结果可知,采用灰色绝对接近关联度模型对轴承健康状态的辨识取得了较理想的效果,能够准确辨识轴承的健康状态。

为了便于比较,图 11 给出了采用灰色接近关联度的轴承待测样本识别结果。由图可知:正常状态样本与其标准模式关联度约在 0.98~1,而与其他状

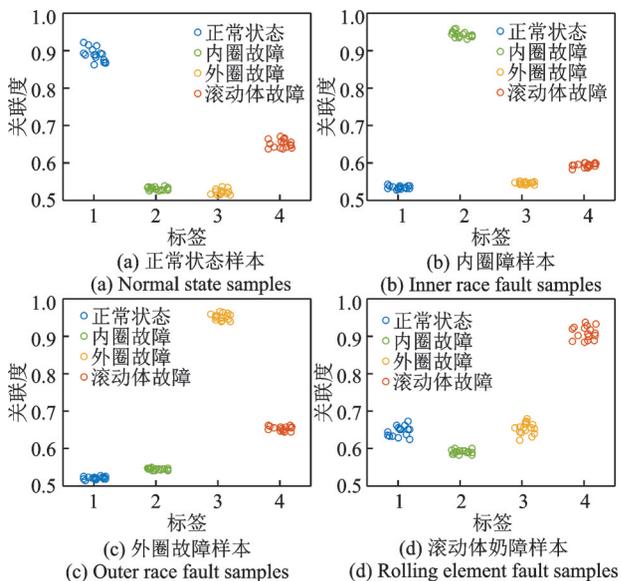


图 10 采用灰色绝对接近关联度的轴承待测样本识别结果
Fig.10 Identification results of bearing samples under test by using grey absolutely close relation degree

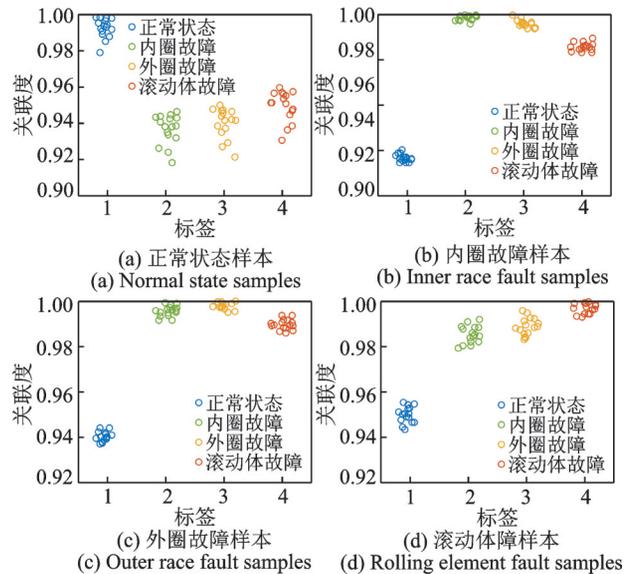


图 11 采用灰色接近关联度的轴承待测样本识别结果
Fig.11 Identification results of bearing samples under test by using grey close relation degree

态关联度约在 0.92~0.96,可以正确分类,但关联度区分较小;对于内圈故障样本,其与内圈和外圈故障标准模式关联度非常接近,易造成误判。另外,通过基于经验模态分解/小波包变换与灰色绝对接近关联度、基于 TQWT 与支持向量机 3 种方法与本研究所提方法进行了对比。不同方法在不同训练集数量下的识别结果如图 12 所示,待识别样本(测试集)数量均为 100。

从图 10~12 的识别结果可以看出:①灰色绝对接近关联度较传统灰色接近关联度具有明显提升,取得了较为理想的识别效果;②支持向量机的分类精度受样本数量的影响较大,灰色关联分析相比于支持向量机对样本数量的要求更低,适合于解决更小样本下的模式识别问题;③在构建的特征向量维

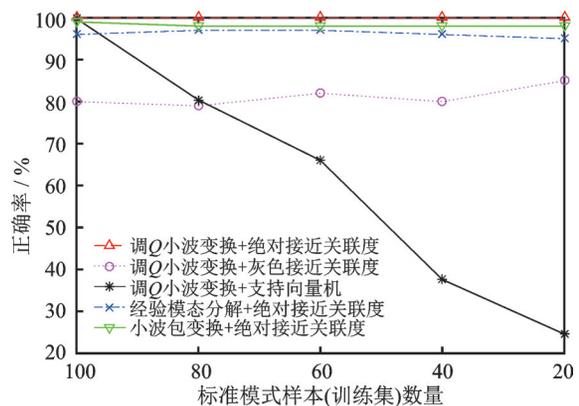


图 12 不同方法在不同训练集数量下的识别结果
Fig.12 Identification results of different methods in different sizes of training sets

数相同的情况下, TQWT 相比于小波包变换取得了更高的识别精度, 这是因为 TQWT 对信号低频段的刻画更为精细; ④ TQWT 相比于经验模态分解, 识别精度更高, 这是因为 TQWT 对频带的划分更为细致, 且经验模态分解理论上难以和频域能量分布匹配。因此, 本研究所提方法可以准确有效地实现轴承故障类型的辨识。

3.2 汽车变速器齿轮箱故障

为了验证该方法对齿轮故障识别的有效性, 对某汽车变速器齿轮箱进行分析。齿轮箱内部结构与外观如图 13 所示。齿轮箱型号为 LC5T81, 包括 5 个前进档和 1 个倒档, 在 3 档齿轮外壳安装加速度传感器, 采集 3 档齿轮不同健康状态时的振动信号, 采样频率为 3 kHz。采集的信号经放大后, 由 A/D 采集卡存储到计算机。第 3 档齿轮的工作参数如表 2 所示。

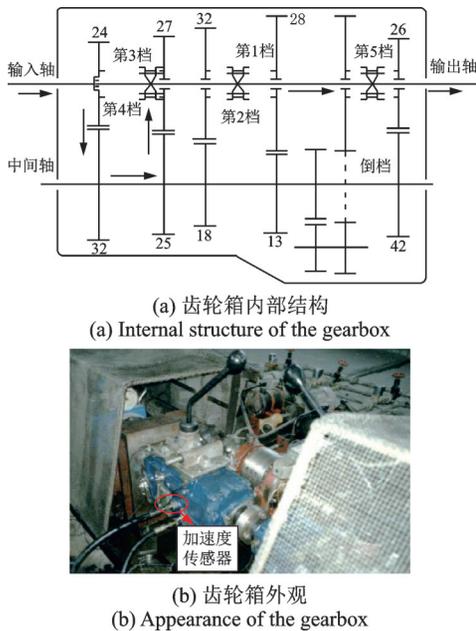


图 13 齿轮箱内部结构与外观

表 2 第 3 档齿轮的工作参数

Tab.2 Parameters of the third gear			
齿轮	齿数	旋转频率/Hz	啮合频率/Hz
主动齿轮	25	20.0	500
被动齿轮	27	18.5	

分别对齿轮正常、磨损和断齿 3 种工况进行采样, 每种健康状态下截取 13 段振动信号, 随机选取 5 段作为标准模式样本, 其余 8 段作为待识别样本。齿轮箱时域信号及其频谱如图 14 所示。

采用 TQWT 对采样获得的振动信号包络进行

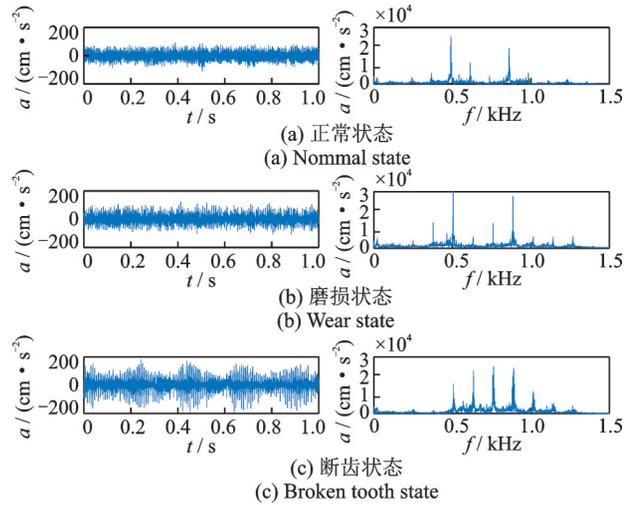


图 14 齿轮箱时域信号及其频谱

频域响应分析, TQWT 的参数设置为 $Q=8, r=3, J=18$, 计算能量分布并构造特征向量。齿轮 3 种工况下标准模式能量分布如图 15 所示。可以看出, 随着齿轮齿面出现磨损, 在相应的频带内会出现共振频率, 因此较高频带的能量所占比例逐渐增大, 出现能量分布从低频向高频转移的现象。当出现断齿时, 能量会集中在高频, 低频的能量所占比例较小。因此, 根据齿轮不同健康状态的能量占比, 可以对齿轮的故障严重程度进行识别。

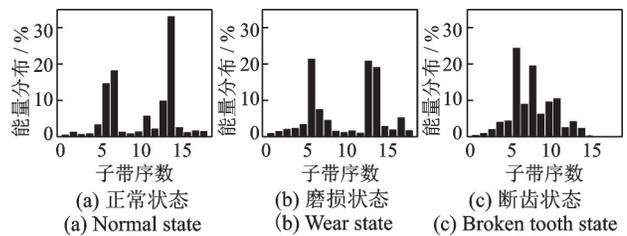


图 15 齿轮 3 种工况下标准模式能量分布图

采用灰色绝对接近关联度模型对 24 个齿轮待测样本进行识别, 齿轮待测样本识别结果如图 16 所示, 识别结果全部正确。其中, 标签 1~3 分别表示正常、磨损和断齿状态。由图可知, 本研究提出的方法能够对齿轮的健康状态和故障严重程度进行有效的辨识与评估。

为了验证所提关联度模型在齿轮健康状态辨识的优越性, 表 3, 4 分别给出了采用所提绝对接近关联度和传统灰色接近关联度的齿轮待测样本部分识别结果。通过对比发现: 虽然传统接近关联度模型也能正确辨识齿轮健康状态, 但其关联度数值过于

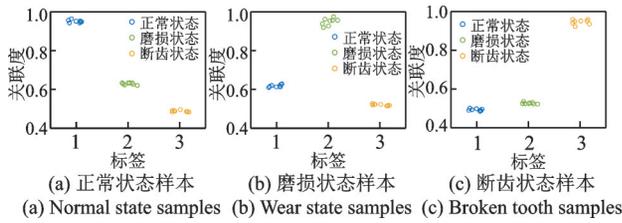


图 16 齿轮待测样本识别结果

Fig.16 Identification results of gear samples under test

表 3 绝对接近关联度的齿轮待测样本部分识别结果

Tab.3 Partial identification results of gear by using proposed grey absolutely close relation degree

样本标签	ρ_1	ρ_2	ρ_3	识别结果
1	0.952 9	0.633 1	0.490 2	1
1	0.951 1	0.635 1	0.490 8	1
2	0.626 3	0.955 7	0.517 5	2
2	0.628 3	0.960 8	0.517 8	2
3	0.487 0	0.523 9	0.959 1	3
3	0.501 6	0.537 1	0.922 5	3

表 4 传统灰色接近关联度齿轮待测样本部分识别结果

Tab.4 Partial identification results of gear by using conventional grey close relation degree

样本标签	ρ_1	ρ_2	ρ_3	识别结果
1	0.997 7	0.996 9	0.990 3	1
1	0.998 3	0.996 3	0.990 9	1
2	0.996 3	0.998 2	0.989 0	2
2	0.995 7	0.998 8	0.988 4	2
3	0.993 2	0.987 8	0.999 4	3
3	0.993 3	0.987 9	0.999 3	3

接近,区分较小;所提灰色绝对接近关联度模型数值区分明显,更能反映待测样本与各健康状态的相似程度,对于齿轮健康状态的故障模式辨识取得了较为理想的效果。

4 结 论

1) 针对车辆旋转部件故障信号的特点,提出了频域特征驱动的灰色故障诊断方法。

2) 对轴承不同故障类型和齿轮不同故障严重程度激励下的振动响应频域特征进行了分析,可知不同故障信息下振动信号及其包络的频域特征也各异。

3) 提出了频域特征驱动的车辆部件灰色故障诊断方法,采用调 Q 小波变换对原始信号包络进行频域响应分析,获取对应不同频段的子信号,以能量分布构建与旋转部件健康状态相对应的特征向量。

4) 针对传统灰色接近关联度的不足,提出了灰色绝对接近关联度模型,解决了两序列折线相交时关联度过大的问题,能够更准确地评估序列之间的接近程度。

5) 以构建的特征向量驱动所提灰色绝对接近关联度模型,对轴承和齿轮的故障模式进行诊断,并对所提方法和其他特征向量构建和模式识别方法进行了比较,进一步验证了所提方法在信号频域特征提取和模式识别精度上的优越性。

参 考 文 献

[1] 沈长青,朱忠奎,黄伟国,等.基于支持向量回归方法的齿轮箱故障诊断研究[J].振动、测试与诊断,2013,33(5):775-781.
SHEN Changqing, ZHU Zhongkui, HUANG Weiguo, et al. Gearbox fault diagnosis based on support vector regression[J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(5): 775-781.(in Chinese)

[2] LI Z P, CHEN J L, ZI Y A, et al. Independence-oriented VMD to identify fault feature for wheel set bearing fault diagnosis of high speed locomotive[J]. Mechanical Systems and Signal Processing, 2017, 85: 512-529.

[3] 张立智,徐卫晓,井陆阳,等.基于EMD-SVD和CNN的旋转机械故障诊断[J].振动、测试与诊断,2020,40(6):1063-1070.
ZHANG Lizhi, XU Weixiao, JING Luyang, et al. Fault diagnosis of rotating machinery based on EMD-SVD and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(6): 1063-1070.(in Chinese)

[4] YANG S P, GU X H, LIU Y Q, et al. A general multi-objective optimized wavelet filter and its applications in fault diagnosis of wheelset bearings[J]. Mechanical Systems and Signal Processing, 2020, 145: 106914.

[5] 李红卫,杨东升,孙一兰,等.智能故障诊断技术研究综述与展望[J].计算机工程与设计,2013,34(2):632-637.
LI Hongwei, YANG Dongsheng, SUN Yilan, et al. Study review and prospect of intelligent fault diagnosis technique[J]. Computer Engineering and Design, 2013, 34(2): 632-637.(in Chinese)

[6] 袁胜发,褚福磊.支持向量机及其在机械故障诊断中的应用[J].振动与冲击,2007,26(11):29-35,58.
YUAN Shengfa, CHU Fulei. Support vector machines and its applications in machine fault diagnosis[J]. Journal of Vibration and Shock, 2007, 26(11): 29-35, 58. (in Chinese)

[7] CUI H Y, QIAO Y Y, YIN Y M, et al. An

- investigation of rolling bearing early diagnosis based on high-frequency characteristics and self-adaptive wavelet de-noising[J]. *Neurocomputing*, 2016, 216: 649-656.
- [8] 沈路, 周晓军, 张文斌, 等. 基于形态滤波与灰色关联度的滚动轴承故障诊断[J]. *振动与冲击*, 2009, 28(11): 17-20.
SHEN Lu, ZHOU Xiaojun, ZHANG Wenbin, et al. Fault diagnosis of rolling element bearing based on morphological filter and grey incidence[J]. *Journal of Vibration and Shock*, 2009, 28(11): 17-20.(in Chinese)
- [9] 王录雁, 王强, 张梅军, 等. 基于EMD的滚动轴承故障灰色诊断方法[J]. *振动与冲击*, 2014, 33(3): 197-202.
WANG Luyan, WANG Qiang, ZHANG Meijun, et al. A grey fault diagnosis method for rolling bearings based on EMD[J]. *Journal of Vibration and Shock*, 2014, 33(3): 197-202.(in Chinese)
- [10] 冉钧, 赵荣珍. 基于频域振幅灰色关联度的转子故障模式辨识[J]. *振动、测试与诊断*, 2014, 33(6): 1019-1024.
RAN Jun, ZHAO Rongzhen. Rotor failure mode identification based on gray correlation analysis of frequency-domain amplitude[J]. *Journal of Vibration, Measurement & Diagnosis*, 2014, 33(6): 1019-1024.(in Chinese)
- [11] 张文斌, 苏艳萍, 普亚松, 等. 基于集合经验模式分解能量分布与灰色相似关联度的齿轮故障诊断[J]. *机械工程学报*, 2014, 50(7): 70-77.
ZHANG Wenbin, SU Yanping, PU Yasong, et al. Gear fault diagnosis method using ensemble empirical mode decomposition energy distribution and grey similar incidence[J]. *Journal of Mechanical Engineering*, 2014, 50(7): 70-77.(in Chinese)
- [12] 李舜酩, 郭海东, 李殿荣. 振动信号处理方法综述[J]. *仪器仪表学报*, 2013, 34(8): 1907-1915.
LI Shunming, GUO Haidong, LI Dianrong. Review of vibration signal processing methods[J]. *Chinese Journal of Scientific Instrument*, 2013, 34(8): 1907-1915.(in Chinese)
- [13] 何正嘉, 訾艳阳, 张周锁, 等. 大型机械设备变工况非平稳动态分析与监测诊断关键技术[J]. *中国机械工程*, 1999, 10(9): 978-981.
HE Zhengjia, ZI Yanyang, ZHANG Zhousuo, et al. Key technologies on dynamic analysis and monitoring-diagnosis of varying operation and nonstationarity for large mechanical equipment[J]. *China Mechanical Engineering*, 1999, 10(9): 978-981.(in Chinese)
- [14] WANG T Y, LIANG M, LI J Y, et al. Rolling element bearing fault diagnosis via fault characteristic order (FCO) analysis[J]. *Mechanical Systems and Signal Processing*, 2014, 45(1): 139-153.
- [15] 李永焯, 丁康, 何国林, 等. 齿轮系统振动响应信号调制边频带产生机理[J]. *机械工程学报*, 2018, 54(5): 105-112.
LI Yongchao, DING Kang, HE Guolin, et al. Modulation sidebands of the vibration signal of gearbox[J]. *Journal of Mechanical Engineering*, 2018, 54(5): 105-112.(in Chinese)
- [16] 何国林, 丁康, 林慧斌. 基于匹配追踪的齿轮箱耦合调制振动信号分离方法研究[J]. *机械工程学报*, 2016, 52(1): 102-108.
HE Guolin, DING Kang, LIN Huibin. Matching pursuit method for coupling modulation signal separation of gearbox vibration[J]. *Journal of Mechanical Engineering*, 2016, 52(1): 102-108.(in Chinese)
- [17] SELESNICK I W. Wavelet transform with tunable Q-factor[J]. *IEEE Transactions on Signal Processing*, 2011, 59(8): 3560-3575.
- [18] HUANG H. Methods for rolling element bearing fault diagnosis under constant and time-varying rotational speed conditions[D]. Ottawa, Canada: University of Ottawa, 2018.
- [19] SHI J J, HUANG W G, SHEN C Q, et al. Dual-guidance-based optimal resonant frequency band selection and multiple ridge path identification for bearing fault diagnosis under time-varying speeds[J]. *IEEE Access*, 2019, 7: 144995-145012.
- [20] SHEN G X, HAN C Y, CHEN B K, et al. Fault analysis of machine tools based on grey relational analysis and main factor analysis[J]. *Journal of Physics: Conference Series*, 2018, 1069(1): 012112.
- [21] DENG J. Grey information space[J]. *Journal of Grey Systems*, 1989, 1(2): 103-117.
- [22] 刘思峰, 谢乃明, FORREST J. 基于相似性和接近性视角的新型灰色关联分析模型[J]. *系统工程理论与实践*, 2010, 30(5): 881-887.
LIU Sifeng, XIE Naiming, FORREST J. On new models of grey incidence analysis based on visual angle of similarity and nearness[J]. *Systems Engineering-Theory & Practice*, 2010, 30(5): 881-887.(in Chinese)



第一作者简介: 苏舟, 男, 1996年12月生, 硕士生。主要研究方向为旋转机械关键零部件故障诊断。
E-mail: boatsuzhou@163.com

通信作者简介: 石娟娟, 女, 1985年1月生, 博士、教授、博士生导师。主要研究方向为车辆关键零部件状态监测与故障诊断。
E-mail: jshi091@suda.edu.cn