

多尺度复合稀疏的齿轮箱复合故障诊断研究*

周浩轩¹, 温广瑞^{1,2}, 黄鑫¹, 董书志¹, 周鑫¹

(1. 西安交通大学机械工程学院 西安, 710049)

(2. 新疆大学机械工程学院 乌鲁木齐, 830047)

摘要 现代机械设备传动系统中轴承和齿轮容易发生局部疲劳故障, 单一部件典型故障引起的载荷波动极易造成其他部件继发性疲劳故障, 使机械传动系统呈现多部件复合故障状态。针对齿轮箱传动系统中轴承和齿轮复合故障诊断问题, 提出了基于多尺度卷积核匹配复合正则化的卷积稀疏编码 (multiscale compound regularized convolutional sparse coding, 简称 MCR CSC) 分离诊断算法。首先, 根据齿轮箱轴承和齿轮典型复合故障所呈现出的稀疏性与尺度特性进行了模型假设; 其次, 依据不同故障的信号尺度特性与分布特点提出了多尺度卷积核与复合正则化约束的概念, 并建立了多成分卷积分离模型; 最后, 通过交替方向乘子 (alternating direction method of multipliers, 简称 ADMM) 优化架构将频域转化后的优化方程分解为子问题进行交替求解, 对分离卷积重构后的故障信号进行谱分析得到对应典型故障频率分布。实际齿轮箱故障模拟实验表明, 所提算法在随机噪声和谐波干扰下仍具有优良故障分离诊断能力。

关键词 卷积稀疏; 多尺度卷积核; 复合正则化; 机械复合故障; 齿轮箱

中图分类号 TH165.3; TN911.72

引言

作为众多机械设备中应用范围最广的回转部件系统, 齿轮箱在机械传动中发挥着不可替代的作用。随着机械设备的运行环境日益严苛, 齿轮箱中轴承、齿轮等回转体部件极易发生损坏, 对其运行状态进行有效的监测和诊断至关重要。目前, 相关研究较多关注轴承或齿轮等单一部件的故障检测^[1-3], 常用的方法有谱峭度^[4]、小波分解^[5]、谱分析等及其改进方法^[6], 这些方法大都无法同时对多部件复合故障进行分析。此外, 由于振动传感器一般布置在机体外表面, 在复杂组合回转结构和机匣的影响下, 振动传递路径的时变耦合特性使得故障分量被掩盖在各种干扰之中, 一般方法易受到干扰而无法对其进行准确分析和诊断。

对复杂机械信号进行单一源分离是一种解决线性混叠和传递路径耦合的有效思路。典型算法如独立成分分析 (independent component analysis, 简称 ICA)^[7] 已得到许多成功应用^[8-9], 然而 ICA 基于统计独立的假设条件并不适用于所有的情况, 特别是轴承类故障在时域具有典型稀疏性。因此, 稀疏表示理论被引入用以解决复杂的、具有稀疏特征的信号

分离问题。形态成分分析 (morphological component analysis, 简称 MCA) 由于其可利用信号组成成分的形态差异性 (可由不同的字典稀疏表示) 进行信号分离^[10] 而受到一定的关注, 但是该方法与一般的基于预定义字典稀疏表示类似, 需要依据先验专家信息设定满足类独一稀疏性的冗余字典, 根据不同类字典的稀疏表示对潜在分量进行稀疏重构表示。虽然一般常用的字典如与冲击较为匹配的 Dirac 字典、傅里叶字典及小波包字典^[11-12] 能在一定程度上匹配复杂机械信号中的不同成分, 但是在信号恢复上都存在由于匹配度不足和噪声干扰所造成的精度低、需要依据经验选择合适的字典等问题。寻找一种依据信号自身特点自适应学习分离的方法是解决复杂信号自适应分离解耦问题更为有效的途径。

齿轮箱中回转体部件发生故障时, 其振动信号呈现一定的循环平稳特性, 轴承信号经过循环周期抽取算子可以得到特定循环频率正弦分量。齿轮齿面发生故障时, 其啮合频率会受到转频的调制而使幅值产生准周期波动, 可以认为齿轮呈现的调制故障在时间大尺度上也具有一定的稀疏性, 轴承和齿轮故障信号总体在时域上呈现一定的平移不变性。

* 国家自然科学基金资助项目 (51775409)

收稿日期: 2020-06-25; 修回日期: 2020-10-25

近年提出的卷积稀疏编码^[13](convolutional sparse coding, 简称 CSC)很好地契合了这种平移不变性, 已被应用于音频分类^[14-15]和反卷积网络^[16]中。与一般意义上将信号的稀疏表示建模为冗余字典原子与稀疏系数的组合不同, 卷积稀疏编码将信号的移不变特性建模为卷积核与对应的稀疏特征图谱的卷积。在故障诊断领域, CSC 已应用于轴承的故障特征提取与盲解卷中, 取得了一定的效果^[17-18], 但这些应用并未关注卷积核尺度的问题, 且都是单一基于稀疏性差异的噪声、故障成分解耦。由于 CSC 有着与回转体部件故障时域信号特性的高度适应性, 笔者主要研究其在齿轮箱传动系统多分量复合故障分离诊断方面的应用。

针对齿轮箱中存在多故障并存的问题, 笔者提出了基于多尺度复合正则化卷积稀疏编码的故障分离诊断方法, 改进的多尺度卷积核相对于定尺度卷积核可以提供更加丰富的感受野尺寸, 从而提高分离结果的分辨率与信噪比。依据潜在成分分布特性设置的多范数结合的正则化方法可以更好地捕捉不同信号成分, 从而实现潜在成分的精确分离。实际齿轮箱复合故障实验验证了整合多尺度核与复合正则约束的 MRCSC 方法的有效性。

1 理论介绍

1.1 卷积稀疏编码

稀疏字典学习算法旨在将稀疏约束下的输入向量 $\{y_n\}_{n=1}^N$ 的集合分解为过完备字典 A 中原子 a_k 线性组合, 需要求解如下最小化问题^[19]

$$\begin{aligned} \arg \min_{A, x} \frac{1}{2} \sum_{n=1}^N \|y_n - Ax_n\|_2^2 + \mu \|x_n\|_1 \\ \text{s.t. } \|a_k\|_2 \leq 1 \quad (k=1, 2, \dots, m) \end{aligned} \quad (1)$$

其中: μ 为 L_1 项的惩罚因子参数。

不等式保证原子的能量尺度统一性, 上述优化问题可以通过 Basis pursuit^[20] 或者 Match pursuit 算法^[21] 进行求解。稀疏编码模型假设输入向量中的成分是相互独立的, 而在现实信号或图像中许多特征具有平移不变性, 这将导致所学习到的冗余字典中部分基函数 a_k 是相互的线性变换形式, 增加计算复杂度的同时并未很好地表征信号中的移不变性, 而卷积稀疏编码直接将平移不变性建模到优化函数中^[22]

$$\begin{aligned} \arg \min_{A, x} \frac{1}{2} \sum_{n=1}^N \|y_n - a_k * x_n\|_2^2 + \mu \|x_n\|_1 \\ \text{s.t. } \|a_k\|_2 \leq 1 \quad (k=1, 2, \dots, m) \end{aligned} \quad (2)$$

其中: $*$ 表示卷积操作。

卷积稀疏编码通过将移不变卷积核 a_k 与特征图谱 x_n 卷积结果进行求和来逼近输入信号 y_n , 从而更好地捕捉信号中的准周期移不变成分。

1.2 模型假设

假设单通道振动信号传感器采集到的多故障信号 $S(t)$ 中各分量是线性混叠的, 则有

$$S(t) = \sum_i^n s_i \quad (3)$$

其中: s_i 为一个信号被分解后的分量信号。

一般情况下, 假设采集到的信号包含

$$S(t) = s_{\text{bearing}} + s_{\text{gear}} + s_{\text{harmonic}} + s_{\text{noise}} \quad (4)$$

其中: $s_{\text{bearing}}, s_{\text{gear}}$ 分别表示轴承和齿轮的故障成分; s_{harmonic} 与 s_{noise} 分别表示谐波干扰和高斯白噪声干扰。

由于轴承与齿轮故障在时域上的准周期特性, 其信号可以建模为

$$s_{\text{bearing}} = a_{\text{bearing}} * x_{\text{bearing}} \quad (5)$$

$$s_{\text{gear}} = a_{\text{gear}} * x_{\text{gear}} \quad (6)$$

其中: a 为对应的卷积核; x_{bearing} 和 x_{gear} 为对应的卷积系数。

$$x_{\text{bearing}} \sim \text{Laplace}(0, \lambda); \text{Sparseness}(x_{\text{bearing}}) \leq \alpha \quad (7)$$

$$x_{\text{gear}} \sim \text{Laplace}(0, \lambda); \text{Sparseness}(x_{\text{gear}}) \leq \alpha \quad (8)$$

其中: $\text{Sparseness}(\cdot)$ 为稀疏度; α 为满足的稀疏性度量。

同样, s_{harmonic} 与 s_{noise} 可以建模为

$$s_{\text{harmonic}} = d_{\text{harmonic}} * u_{\text{harmonic}} \quad (9)$$

$$s_{\text{noise}} = d_{\text{noise}} * u_{\text{noise}} \quad (10)$$

d_{noise} 和 d_{harmonic} 满足

$$d_{\text{noise}} \sim \mathcal{N}(0, \sigma_n^2) \quad (11)$$

$$d_{\text{harmonic}} \sim \mathcal{N}(0, \sigma_n^2) \quad (12)$$

一般情况下, 机械传动系统各部件的结构与动力学存在一定的差异, 设传动系统各部件故障振动响应与干扰满足线性不相关特性, 结合稀疏域分离模型假定^[23], 卷积核应满足下列条件

$$\begin{cases} 0 = a_{\text{bearing}} * k_1 + a_{\text{gear}} * k_2 + a_{\text{harmonic}} * k_3 + a_{\text{noise}} * k_4 \\ \text{iff } k_j = 0 \quad (j=1, 2, 3, 4) \end{cases} \quad (13)$$

综上, 结合单通道振动信号成分线性混叠假设, 求解出每种成分对应的卷积核与卷积系数即可对各类成分进行有效分离。

1.3 提出的方法

依据复杂机械故障信号模型假设,当轴承或齿轮发生故障时,其故障成分在时域满足一定的稀疏性,而信号中存在的噪声和谐波干扰不是稀疏的。此外,满足稀疏性的轴承和齿轮故障时域特征波形在时间尺度上是不同的,据此结合卷积稀疏的移不变表征特征,提出多尺度复合正则化卷积稀疏模型逼近齿轮箱复合故障机械信号,卷积核与特征图谱的优化函数为

$$\begin{aligned} \arg \min_{A, D, X, U} & \frac{1}{2} \| S - A * X - D * U \|_2^2 + \eta \alpha \| X \|_1 + \\ & \gamma \| U \|_2^2 \\ \text{s.t.} & \| A \|_2^2, \| D \|_2^2 \leq 1 \end{aligned} \quad (14)$$

其中: η 为稀疏性度量正则系数; γ 为 L_2 范数正则因子; A, D 为对应的故障信号和干扰信号的卷积核矩阵; X, U 为对应的卷积特征图谱矩阵; S 为复合故障信号输入。

L_1 范数提供了轴承和齿轮稀疏性约束, L_2 范数提供了高斯噪声和谐波缓变成分的正则约束,依据不同成分特性设定的 L_1 和 L_2 范数的联合正则化避免了卷积稀疏编码的线性混叠。

为了保证齿轮故障信号在大尺度上的稀疏性质,以便与轴承故障进行组合稀疏正则化,从而实现关联成分的精确分离,笔者提出多尺度卷积核以提升轴承故障成分的细节分辨性和齿轮故障成分的大尺度性。因此,卷积核 A 需满足以下设定要求

$$\begin{aligned} A &= \{ a_{\text{bearing}}, a_{\text{gear}} \} \\ \text{s.t.} & \begin{cases} \frac{\omega f_s}{f_{\text{BP}}} \leq \text{length}(a_{\text{bearing}}) \leq \frac{f_s}{f_{\text{BF}}} \\ \frac{\omega f_s}{f_{\text{RF}}} \leq \text{length}(a_{\text{gear}}) \leq \frac{f_s}{f_{\text{RF}}} \end{cases} \end{aligned} \quad (15)$$

其中: f_s, f_{BF} 和 f_{RF} 分别为信号的采样频率、轴承的故障特征频率及故障齿轮轴的转频; ω 为调整因子,其取值范围为 $[0, 1]$ 。

L_2 范数正则化的谐波干扰由于其在时域上的连续性和大尺度性,设置大尺度卷积核来提升模型针对该类成分的感受野;而高斯白噪声成分由于在时域上的随机性,需要设置小尺度的卷积核提升细节分辨能力。因此,卷积核 B 满足

$$\begin{aligned} D &= \{ d_{\text{harmonic}}, d_{\text{noise}} \} \\ \text{s.t.} & \begin{cases} \text{length}(d_{\text{harmonic}}) \geq \text{length}(a_{\text{gear}}) \\ \text{length}(d_{\text{noise}}) \leq \text{length}(a_{\text{bearing}}) \end{cases} \end{aligned} \quad (16)$$

为了求解优化问题(14),笔者采用交替求解的优化思路,首先随机初始化各个卷积核,固定卷积核之后求解特征图谱 X 和 U ,随后固定求解得到的 X 和 U ,并求解对应的卷积核,交替进行,直至收敛或达到最大迭代次数。

1.3.1 复合正则特征图谱求解

在CSC中基于压缩映射原理的交替求解不动点的思路提供了一个有效的优化问题求解框架,笔者也引入交替方向乘法^[13]对优化问题(14)进行求解。一般地,ADMM是一种最小化2个不需要区分的凸函数之和的方法。设存在如下优化问题

$$\min_z f(z) + g(z) \quad (17)$$

ADMM可以将2个子问题 $f(z)$ 和 $g(z)$ 拆分,并为保证子问题非严格凸时的收敛性加入平方正则项,有

$$z^{l+1} = \arg \min_z f(z) + \frac{\rho}{2} \| z - q^l + p^l \|^2 \quad (18)$$

$$p^{l+1} = \arg \min_p g(z^{l+1}) + \frac{\rho}{2} \| z^{l+1} + p - q^l \|^2 \quad (19)$$

$$q^{l+1} = q^l + \rho(p^{l+1} - z^{l+1}) \quad (20)$$

其中: q 为辅助变量; p 为对偶变量。

类似高斯赛德尔迭代法,循环交替迭代方程(18)~(20),直至收敛输出优化问题的解 z^{l+1} 。

对于式(14)中优化特征图谱 X 和 U ,当卷积核固定时,有如下问题

$$\begin{aligned} \min_{X, U} & \frac{1}{2} \| Y - A * X - D * U \|_2^2 + \eta \alpha \| X \|_1 + \\ & \gamma \| U \|_2^2 \end{aligned} \quad (21)$$

假定 A 和 D 已知且固定后,式(21)依据ADMM可以将其分解为如下两个子问题

$$f_{X, U} = \arg \min_{X, U} \frac{1}{2} \| Y - A * X - D * U \|_2^2 \quad (22)$$

$$g_{X, U} = \arg \min_{X, U} \eta \alpha \| X \|_1 + \gamma \| U \|_2^2 \quad (23)$$

构建子问题式(22),(23)的高斯赛德尔交替迭代形式为

$$\begin{cases} X^{l+1}, U^{l+1} = \arg \min_{X, U} \frac{1}{2} \| Y - A * X - D * U \|_2^2 + \\ \dots + \frac{\rho}{2} \| W \|_2^2 \\ W = X + U - Q_X^l + P_X^l - Q_U^l + P_U^l \end{cases} \quad (24)$$

$$\begin{cases} P_X^{l+1}, P_U^{l+1} = \arg \min_P \|X^{l+1}\|_1 + \dots + \\ \|U^{l+1}\|_2^2 + \frac{\rho}{2\eta\alpha} \|G\|_2^2 + \frac{\rho}{2\gamma} \|H\|_2^2 \\ G = X^{l+1} - P - Q^l \\ H = U^{l+1} - P - Q^l \end{cases} \quad (25)$$

$$\begin{cases} Q_X^{l+1} = Q_X^l + \rho(P_X^{l+1} - X^{l+1}) \\ Q_U^{l+1} = Q_U^l + \rho(P_U^{l+1} - U^{l+1}) \end{cases} \quad (26)$$

与式(18)~(20)类似, P 和 Q 分别为对偶矩阵与辅助变量矩阵。由于求解式(24)中涉及到多尺度复合时域卷积操作,根据卷积定理,运用快速傅里叶变换将其转化到频域进行计算以加快效率和合并多尺度卷积核,式(24)的频域形式可以写为

$$\begin{cases} \hat{X}^{l+1}, \hat{U}^{l+1} = \arg \min_{X,U} \frac{1}{2} \|\hat{Y} - \hat{A}\hat{X} - \hat{D}\hat{U}\|_2^2 + \\ \frac{\rho}{2} \|\hat{W}\|_2^2 \\ \hat{W} = \hat{X} + \hat{U} - \hat{Q}_X^l + \hat{P}_X^l - \hat{Q}_U^l + \hat{P}_U^l \end{cases} \quad (27)$$

其中:上修饰符表示参数对应的频域形式。

由于傅里叶变换中的补零操作,时域不同尺度的卷积在频域为同一尺度,故式(27)可以改写为

$$\begin{cases} \hat{C}^{l+1} = \arg \min_{X,U} \frac{1}{2} \|\hat{Y} - \hat{E}\hat{C}\|_2^2 + \frac{\rho}{2} \|\hat{W}\|_2^2 \\ \hat{W} = \hat{C} - \hat{Q}^l + \hat{P}^l \end{cases} \quad (28)$$

其中: $\hat{C} = [\hat{X}; \hat{U}]$; $\hat{P} = [\hat{P}_X; \hat{P}_U]$; $\hat{E} = [\hat{A}; \hat{D}]$ 。

由于式(28)实际上是二次优化问题,设置其梯度为0可以得到其逼近解为

$$\hat{C}^{l+1} = \left(\frac{1}{\rho} \hat{E}^T \hat{E} + I \right)^{-1} \left(\frac{1}{\rho} \hat{E}^T \hat{Y} + \hat{P}^l + \hat{Q}^l \right) \quad (29)$$

针对式(29)的求逆问题, Sherman-Morrison-Woodbury 反演引理^[24]给出

$$\left(\frac{1}{\rho} \hat{E}^T \hat{E} + I \right)^{-1} = I - \frac{1}{\rho} \hat{E}^T \left(I + \frac{1}{\rho} \hat{E} \hat{E}^T \right)^{-1} \hat{E} \quad (30)$$

式(30)中的求逆问题由于已经转换到频域,故可由式(31)计算

$$\left(I + \frac{1}{\rho} \hat{E} \hat{E}^T \right)^{-1} = 1 / \left(1 + \frac{1}{\rho} \sum_{k=1}^m |\hat{e}_k|^2 \right) \quad (31)$$

联立式(29)~(31),并循环迭代直至收敛或达到最大迭代次数,即可求得联合特征谱图矩阵的频域形式 \hat{C}^{l+1} 。对其进行傅里叶反变换即可得到其时域表示 C^{l+1} ,子问题式(25)则可以通过联合阈值处理进行近似

$$P_X^{l+1} = \begin{cases} p_X^l - \eta\alpha/\rho & (p_X^l > \eta\alpha/\rho) \\ 0 & (|p_X^l| \leq \eta\alpha/\rho) \\ p_X^l + \eta\alpha/\rho & (p_X^l < -\eta\alpha/\rho) \end{cases} \quad (32)$$

$$P_U^{l+1} = (\gamma/\rho) P_U^{l+1} \quad (33)$$

1.3.2 多尺度卷积核求解

与特征图谱求解类似,现固定输入特征图谱 X 和 U ,求解卷积核

$$\begin{cases} \arg \min \frac{1}{2} \|Y - A*X - D*U\|_2^2 \\ \|a_k\|_2^2 \leq 1 \\ \|d_k\|_2^2 \leq 1 \end{cases} \quad (34)$$

这是凸约束下的凸优化问题,同样依据 ADMM,式(34)可以转化以下子问题

$$\begin{cases} A^{l+1}, D^{l+1} = \arg \min_{X,U} \frac{1}{2} \|Y - A*X - D*U\|_2^2 + \\ \frac{\rho}{2} \|V\|_2^2 \\ V = A + D - Q_A^l + P_A^l - Q_D^l + P_D^l \end{cases} \quad (35)$$

$$\begin{cases} P_A^{l+1} = \frac{P_A^l}{\|P_A^l\|_2^2} & (\|P_A^l\|_2^2 > 1) \\ P_D^{l+1} = \frac{P_D^l}{\|P_D^l\|_2^2} & (\|P_D^l\|_2^2 > 1) \\ P_A^{l+1} = P_A^l & (\text{其他}) \\ P_D^{l+1} = P_D^l & (\text{其他}) \end{cases} \quad (36)$$

$$\begin{cases} Q_A^{l+1} = Q_A^l + \rho(P_A^{l+1} - A^{l+1}) \\ Q_D^{l+1} = Q_D^l + \rho(P_D^{l+1} - D^{l+1}) \end{cases} \quad (37)$$

同样地, P 和 Q 依然为对应的对偶变量和辅助变量。为求解式(35),将其转化到频域,则有

$$\hat{E}^{l+1} = \left(\frac{1}{\rho} \hat{C}^T \hat{C} + I \right)^{-1} \left(\frac{1}{\rho} \hat{C}^T \hat{Y} + \hat{P}^l + \hat{Q}^l \right) \quad (38)$$

$$\left(\frac{1}{\rho} \hat{C}^T \hat{C} + I \right)^{-1} = I - \frac{1}{\rho} \hat{C}^T \left(I + \frac{1}{\rho} \hat{C} \hat{C}^T \right)^{-1} \hat{C} \quad (39)$$

$$\left(I + \frac{1}{\rho} \hat{C} \hat{C}^T \right)^{-1} = 1 / \left(1 + \frac{1}{\rho} \sum_{k=1}^m |\hat{c}_k|^2 \right) \quad (40)$$

联立式(38)~(40)并进行迭代,即可以求得式(35)的解 \hat{E}^{l+1} 。

综上,笔者提出的 MCRCS 的故障分离诊断方法总体流程图如图1所示。

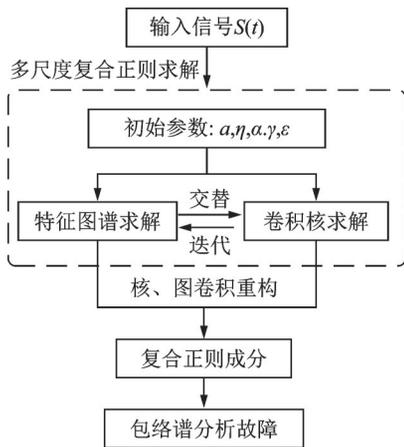
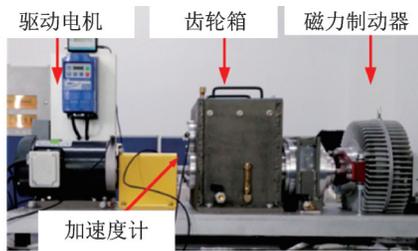


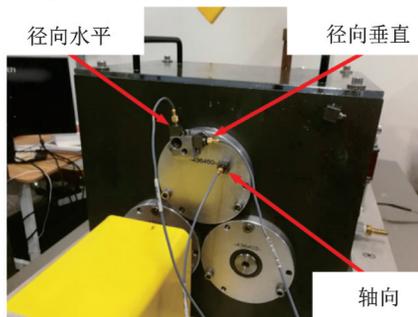
图1 基于MCR CSC方法的机械复合故障诊断流程图
Fig.1 Flow chart of mechanical compound fault diagnosis based on MCR CSC method

2 实验验证

笔者在 Spectra Quest 公司设计的风电设备传动系统诊断模拟平台上进行了齿轮箱复合故障实验和数据采集,见图 2。如图 2(a)所示,平台包括 1 个 2.237 kW 的驱动电机、1 个二级齿轮箱、1 个行星齿轮箱和 1 个电磁制动器,在齿轮箱的输入轴上安装有外圈故障的滚子轴承。直流电动机的速度设置为 1.5 kr/min(旋转频率为 25 Hz)。如图 2(b)所示,使用 3 个加速度传感器来收集齿轮箱在轴向、径向垂直和径向水平方向上的振动信号,其灵敏度为 10.23 mV/g。信号采集卡型号为 DT9837,采样频率为 20 480 Hz,采样点数为 20 480。轴承由 MB 公司制造,型号为



(a) 测试台的总体架构
(a) The overall structure of the test bench

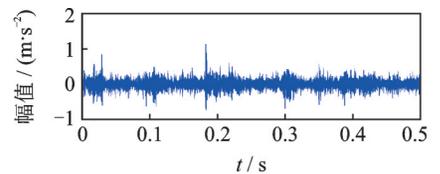


(b) 3 个加速度计的安装布置
(b) Installation arrangement of three accelerometers
图 2 风力发电机传动系统故障模拟实验台

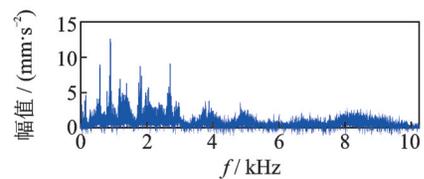
Fig.2 Wind turbine drive system failure simulation test bench

ER-16K。通过加工设置了齿轮箱中间轴齿轮半断齿故障和输入轴轴承外圈故障。故障齿轮啮合频率 $f_z = 900$ Hz,故障齿轮轴转频 $f_{rm} = 10$ Hz,外圈故障特征频率 $f_o = 89.3$ Hz。

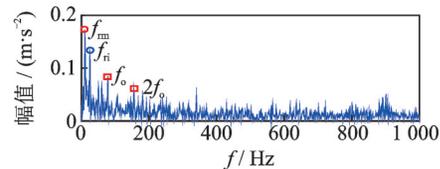
选取半秒 10 240 点数据进行算法验证,原始齿轮箱复合故障信号如图 3 所示,通过频谱和包络谱可知频谱总体比较复杂。其中:齿轮啮合频率成分占主导,没有明显的轴承故障共振频带;包络谱中可以发现故障齿轮所在中间轴转频 f_{rm} 、输入轴转频 f_{ri} 以及受噪声干扰严重的 1,2 阶轴承外圈故障特征频率 f_o ,无典型外圈故障包络谱频率分布。为对比和证明笔者所提方法在处理和解析齿轮箱复合故障信号时的有效性和优越性,引入文献[25]中提出的基于奇异值谱分析(singular spectrum analysis,简称 SSA)的 ICA 方法(SSA-ICA)作为对比方法。其分离齿轮箱信号后分离成分时域波形如图 4 所示,分离成分包络谱如图 5 所示。结合图 4(a)和图 5(a)可知,SSA-ICA 分离得到的成分 1 主要是轴承故障,结合时域与包络谱中故障频率特征可以对其进行轴承故障辨识。由图 4(b)可知,分离成分 2 依然存在轴承外圈故障成分并伴随一定的噪声干扰。由图 5(b,c)可知,成分 3 和 4 中低频部分存在齿轮故障轴转频,但二者的时域波形都受到了较大的噪声干扰。因此,SSA-ICA 算法无法对干扰成分进行有效分离,各分离成分中存在一定的相互混叠。



(a) 原始信号时域波形
(a) Time domain waveform of the original signal



(b) 原始信号频谱
(b) Spectrum of the original signal



(c) 原始信号包络谱
(c) Envelope spectrum of the original signal

图 3 原始齿轮箱复合故障信号

Fig.3 Gearbox compound fault signal

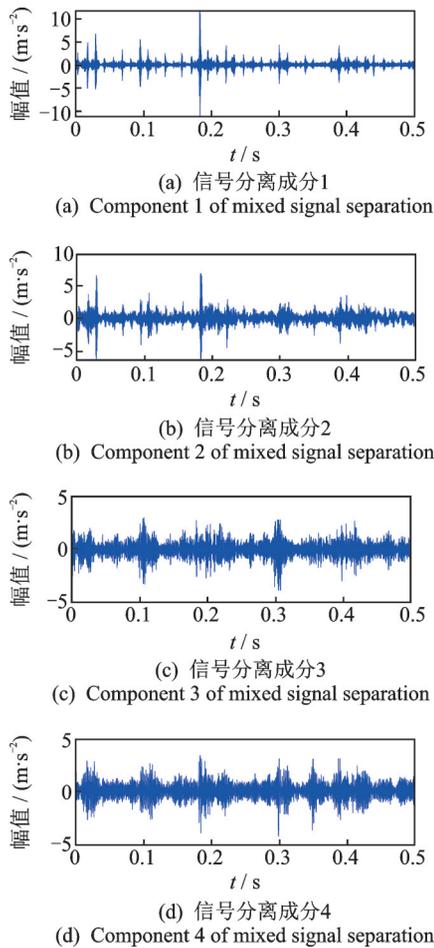


图 4 SSA-ICA 算法分离齿轮箱信号后分离成分时域波形
Fig.4 The time-domain waveform of the separated components after the SSA-ICA algorithm separates the gear-box signal

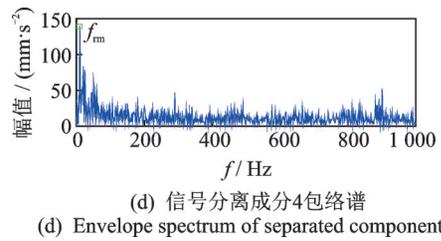
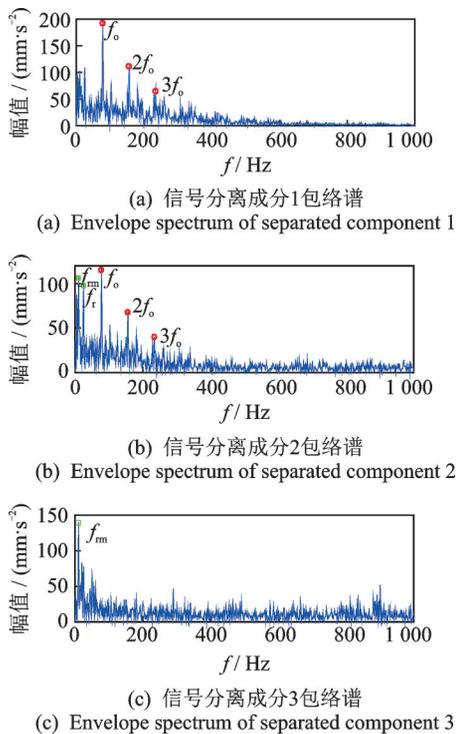


图 5 SSA-ICA 算法分离信号后分离成分包络谱
Fig.5 Envelope spectrum of separated components after separation of signal by SSA-ICA algorithm

根据笔者提出的 MCRSC 算法,设置故障卷积核 A 中对应的卷积核尺度为 100,800;干扰卷积核 D 中卷积核尺度为 1 000,10。MCRSC 重构后的轴承外圈故障信号和齿轮半断齿故障时域信号分离结果如图 6 所示,分别对其进行频谱和包络谱分析,结果如图 7,8 所示。

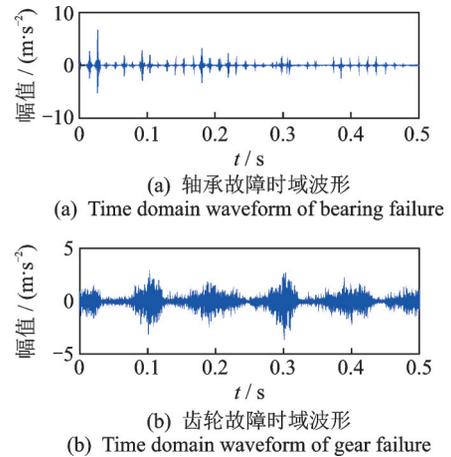


图 6 MCRSC 故障时域信号分离结果
Fig.6 MCRSC fault time domain signal separation results

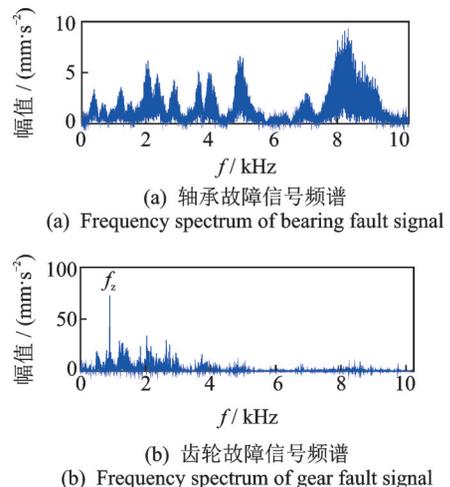


图 7 轴承和齿轮故障分离后的频谱

Fig.7 Spectrum of bearing and gear fault after separation

由图 6~8 可以发现,轴承故障和齿轮故障得到了很好的分离,对分离后的信号进行频谱和包络谱

分析,其对应的故障特征频率明显,因此诊断更为准确可靠。此外,干扰成分时域波形如图9所示,可以发现时域中呈现一定频率的谐波趋势,表明原始信号中存在一定的谐波干扰,所提方法实现了有效的故障成分分离及噪声干扰成分分离。对此类能量较小的干扰谐波进行分离,避免了其成分在故障信号中的混叠,从而提高了分离后故障信号的信噪比。

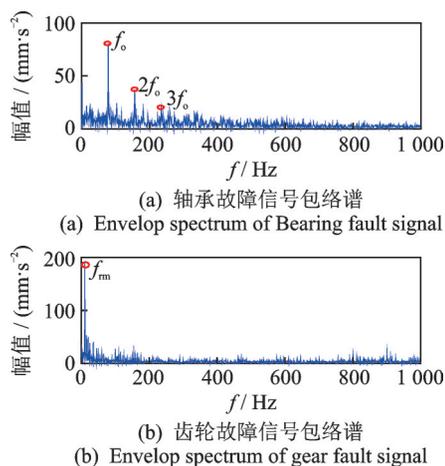


图8 轴承和齿轮故障信号分离后的包络谱

Fig.8 Envelope spectrum after bearing and gear fault signal separation

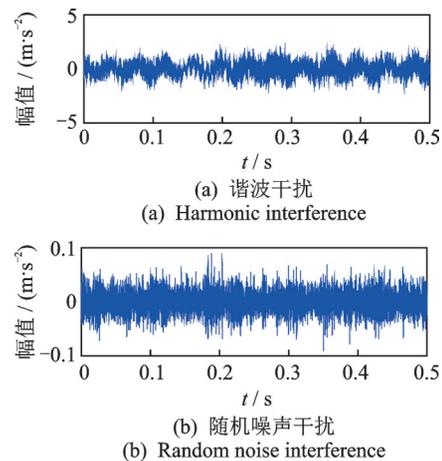


图9 干扰成分时域波形

Fig.9 Time-domain waveform of interference component

3 结束语

齿轮箱中由于部件较多,在载荷波动的工况下轴承和齿轮经常伴随着复合故障的发生。本研究提出多尺度复合正则化卷积稀疏分离诊断算法对线性混叠和耦合的复合故障进行分离,依据轴承和齿轮的故障动力学差异提出了多尺度卷积核的思想,可以更好地实现与故障成分的匹配。针对复合故障信号中各成分的统计学差异提出复合正则化的稀疏模

型,将模型的优化问题转化到频域,实现了多尺度卷积核的融合求解,并运用交替方向乘法中交替迭代的求解框架,将频域优化问题分解为子问题交替迭代求解,实现了复合故障的有效分离和诊断,避免了高斯噪声和缓变谐波干扰。对比单通道盲源分离方法,基于齿轮箱的复合故障模拟实验验证了所提算法在复合故障分离诊断应用上的优良性能。

参 考 文 献

- [1] PEETERS C, ANTONI J, HELSEN J. Blind filters based on envelope spectrum sparsity indicators for bearing and gear vibration-based condition monitoring[J]. Mechanical Systems and Signal Processing, 2020, 138: 106556.
- [2] RANDALL R B, SMITH W A. Detection of faulty accelerometer mounting from response measurements [J]. Journal of Sound and Vibration, 2020, 477: 115318.
- [3] MOSHREFZADEH A, FASANA A, ANTONI J. The spectral amplitude modulation: a nonlinear filtering process for diagnosis of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2019, 132: 253-276.
- [4] ANTONI J, RANDALL R B. The spectral kurtosis: application to the vibratory surveillance and diagnostics of rotating machines [J]. Mechanical Systems and Signal Processing, 2006, 20(2):308-331.
- [5] QIN Y. A new family of model-based impulsive wavelets and their sparse representation for rolling bearing fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2017, 65(3):2716-2726.
- [6] WANG L, SHAO Y. Fault feature extraction of rotating machinery using a reweighted complete ensemble empirical mode decomposition with adaptive noise and demodulation analysis[J]. Mechanical Systems and Signal Processing, 2020, 138:106545.
- [7] 崔玲丽, 吴春光, 邬娜. 基于 EMD 与 ICA 的滚动轴承复合故障诊断[J]. 北京工业大学学报, 2014, 40(10): 1459-1464.
CUI Lingli, WU Chunguang, WU Na. Composite fault diagnosis of rolling bearings based on EMD and ICA algorithm [J]. Journal of Beijing University of Technology, 2014, 40(10):1459-1464. (in Chinese)
- [8] 胥永刚, 孟志鹏, 陆明. 双树复小波包和 ICA 用于滚动轴承复合故障诊断[J]. 振动、测试与诊断, 2015, 35(3):513-518.
XU Yonggang, MENG Zhipeng, LU Ming. Dual-tree complex wavelet packet and ICA for compound fault di-

- agnosis of rolling bearings [J]. *Journal of Vibration, Measurement & Diagnosis*, 2015, 35(3): 513-518. (in Chinese)
- [9] 胥永刚, 孟志鹏, 赵国亮. 基于双树复小波变换的轴承复合故障诊断研究[J]. *仪器仪表学报*, 2014, 35(2): 447-452.
XU Yonggang, MENG Zhipeng, ZHAO Guoliang. Study on compomld falllt diagnosis of rolling bearing based ondual-tree complex wavelet transform [J]. *Chinese Journal of Scientmc Instmment*, 2014, 35(2): 447-452. (in Chinese)
- [10] 杨杰, 郑海起, 关贞珍, 等. 基于核形态成分分析的齿轮箱复合故障诊断研究 [J]. *振动与冲击*, 2012(10): 102-106.
YANG Jie, ZHENG Haiqi, GUAN Zhenzhen, et al. Compound fault diagnosis for gearbox based on kernel morphological component analysis[J]. *Journal of Vibration and Shock*, 2012(10): 102-106. (in Chinese)
- [11] 邓韬, 林建辉, 黄晨光, 等. 基于索引冗余字典的轴承故障组稀疏分类方法研究 [J]. *振动与冲击*, 2019, 38(7): 9-16.
DENG Tao, LIN Jianhui, HUANG Chenguang, et al. Group sparse representation-based classification method of bearing faults based on index redundant dictionary [J]. *Journal of Vibration and Shock*, 2019, 38(7): 9-16. (in Chinese)
- [12] 周浩轩, 刘义民, 刘韬. 基于衰减余弦字典和稀疏特征符号搜索算法的轴承微弱故障特征提取 [J]. *振动与冲击*, 2019, 38(21): 164-171.
ZHOU Haoxuan, LIU Yimin, LIU Tao. Bearing weak fault feature extraction based on attenuated cosine dictionary and sparse feature sign search algorithm [J]. *Journal of Vibration and Shock*, 2019, 38(21): 164-171. (in Chinese)
- [13] HEIDE F, HEIDRICH W, WETZSTEIN G. Fast and flexible convolutional sparse coding [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA, USA: IEEE, 2015: 5135-5143.
- [14] BRISTOW H, ERIKSSON A, LUCEY S. Fast convolutional sparse coding [C]// *2013 IEEE Conference on Computer Vision and Pattern Recognition*. Portland, Oregon, USA: IEEE, 2013: 391-398.
- [15] BARAJAS-SOLANO C, RAMIREZ J M, ARGUELLO H. Convolutional sparse coding framework for compressive spectral imaging [J]. *Journal of Visual Communication and Image Representation*, 2020, 66: 102690.
- [16] LIU W, LIU Z, YU Z, et al. Decoupled networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT, USA: IEEE, 2018: 2771-2779.
- [17] DING J. Fault detection of a wheelset bearing in a high-speed train using the shock-response convolutional sparse-coding technique [J]. *Measurement*, 2018, 117: 108-124.
- [18] DU Z, CHEN X, ZHANG H. Convolutional sparse learning for blind deconvolution and application on impulsive feature detection [J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(2): 338-349.
- [19] ZHOU H, LI H, LIU T, et al. A weak fault feature extraction of rolling element bearing based on attenuated cosine dictionaries and sparse feature sign search [J]. *ISA Transactions*, 2020, 97: 143-154.
- [20] DONOHO D L, TSAIG Y, DRORI I, et al. Sparse solution of underdetermined systems of linear equations by stagewise orthogonal matching pursuit [J]. *IEEE Transactions on Information Theory*, 2012, 58(2): 1094-1121.
- [21] MALLAT S G, ZHANG Z. Matching pursuits with time-frequency dictionaries [J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397-3415.
- [22] BLUMENSATH T, DAVIES M. Sparse and shift-invariant representations of music [J]. *IEEE Transactions on Audio, Speech, and Language Processing*, 2005, 14(1): 50-57.
- [23] 埃拉德, 曹铁勇. 稀疏与冗余表示: 理论及其在信号与图像处理中的应用 [M]. 北京: 国防工业出版社, 2015: 46-48.
- [24] ŠOREL M, ŠROUBEK F. Fast convolutional sparse coding using matrix inversion lemma [J]. *Digital Signal Processing*, 2016, 55: 44-51.
- [25] MADDIRALA A K, SHAIK R A. Separation of sources from single-channel EEG signals using independent component analysis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 67(2): 382-393.



第一作者简介:周浩轩,男,1995年7月生,博士生。主要研究方向为旋转机械故障诊断、机械设备状态监测、预测与工业大数据分析。曾发表《基于衰减余弦字典和稀疏特征符号搜索算法的轴承微弱故障特征提取》(《振动与冲击》2019年第38卷第21期)等论文。

E-mail: zhxharry@Foxmail.com