DOI: 10.3901/JME.2019.07.044

基于改进开关卡尔曼滤波的轴承故障特征提取方法*

崔玲丽¹ 王鑫¹ 王华庆² 胥永刚¹ 张建宇¹

(1. 北京工业大学机械工程与应用电子技术学院 北京 100124;

2. 北京化工大学机电工程学院 北京 100029)

摘要: 提出了一种基于改进开关卡尔曼滤波的滚动轴承故障特征提取新方法, 与传统卡尔曼滤波算法相比, 该方法每次迭代只需当前监测数据测量值和上一时刻最优估计值, 计算效率高, 具有较强实时性。首先将故障轴承振动信号分为故障冲击振动和正常振动两种成分; 其次, 针对故障冲击振动和正常振动两种状态, 分别建立基于轴承质量-弹簧-阻尼系统动力学脉冲响应的卡尔曼滤波器及线性卡尔曼滤波器模型; 然后, 应用基于贝叶斯估计的开关卡尔曼滤波算法对振动信号进行状态估计; 最终, 通过时域迭代滤波, 滤除噪声并识别故障冲击成分, 实现轴承故障特征提取。仿真和试验信号分析结果表明了所提方法的可行性和有效性。

关键词: 开关卡尔曼滤波; 特征提取; 动力学模型; 滚动轴承

中图分类号: TH17

Feature Extraction of Bearing Fault Based on Improved Switching Kalman Filter

CUI Lingli¹ WANG Xin¹ WANG Huaqing² XU Yonggang¹ ZHANG Jianyu¹

(1. School of Mechanical Engineering & Applied Electronics, Beijing University of Technology, Beijing 100124;

2. School of Mechanical & Electrical Engineering, Beijing University of Chemical Technology, Beijing 100029)

Abstract: A new method of fault feature extraction for rolling bearings based on improved switching Kalman filter is proposed. Compared with the traditional Kalman filter algorithm, this method only needs the current measurement value and the optimal estimation of the previous moment in each iteration, so it has high computational efficiency and strong real-time performance. Firstly, the vibration signals of fault bearings are divided into two parts: Fault impulse vibration and normal vibration. Secondly, the Kalman filter model based on the dynamic impulse response of the bearing mass-spring-damper system and the linear Kalman filter model are established respectively for the fault impulse vibration and the normal vibration. Then, the state estimation of vibration signals is carried out by using the switching Kalman filter algorithm based on Bayesian estimation. Finally, the bearing fault feature extraction is realized by filtering noise and identifying fault impulse components through time domain iteration filtering. The simulation and experimental results show the feasibility and effectiveness of the proposed method.

Key words: switching Kalman filter; feature extraction; dynamic model; rolling bearing

0 前言

各类高精尖机械装备的涌现, 互联网、物联网等的不断发展, 推动了机械故障诊断领域进入“大数据”时代^[1]。为了保证机械装备的可靠运行, 常需要布置数量较多的传感器来监测设备运行状态。

这不可避免导致数据量增加, 给存储和后续的计算带来巨大的压力。机械设备较多处于高速运转状态, 或者处于承受较大载荷状态, 因而实时监测其健康状况十分必要, 能够及时避免因设备失效导致的经济损失、人身安全事故等。

滚动轴承作为机械设备中的常见部件极为容易失效, 进而可能导致整个设备损坏, 因此对其进行及时有效地故障诊断十分必要^[2]。针对滚动轴承的故障特征提取已经有大量的学者做了很多先

* 国家自然科学基金资助项目(51575007, 51675035)。20180714 收到初稿, 20181123 收到修改稿

进的工作。贺王鹏等^[3]提出冲击故障特征周期性稀疏为导向的超小波构造方法,有效提取了轴承早期故障的微弱信息。CUI等^[4-5]应用匹配追踪算法、反向传播神经网络等方法进行了轴承故障诊断研究。JIANG等^[6]提出一种无监督多尺度表示学习的智能诊断方法,并在轴承和齿轮箱故障诊断中得到验证。刘东东等^[7]提出故障特征趋势线的概念,有效解决了齿轮噪声和变转速对轴承故障诊断的干扰问题。AHMED等^[8]利用压缩感知方法产生压缩测量信号,后利用深度神经网络学习数据的超完备稀疏表示,再进行最终的故障分类,对极度压缩的测量依然有效。SONG等^[9-10]应用模糊理论和决策树对旋转机械进行故障诊断。前述故障诊断方法均聚焦于诊断效果,但未关注诊断实时性。因此有必要探索一种新型快速智能的故障特征提取方法。

卡尔曼滤波算法是一种时域最小方差估计方法,每次计算只依赖当前的监测数据和上一时刻的最优估计值,因而理论上不需要存储大量的状态监测数据,有望解决硬件存储压力,且计算速度也有所提高。卡尔曼滤波算法自KALMAN^[11]提出以来,在电气系统、航空制导等领域有了大量应用。但将其应用于滚动轴承故障诊断还鲜有研究。KHANAM等^[12-14]将卡尔曼滤波和 H_∞ 滤波应用于轴承故障特征提取。结果表明应用卡尔曼滤波进行滚动轴承故障诊断是可行的,但是所建立的单一滤波器模型不能有效衡量故障信号成分的动态变化,在时域波形中未能明显提取到故障冲击。

基于以上分析,提出一种新型的开关卡尔曼滤波算法进行滚动轴承故障特征提取。开关卡尔曼滤波算法由MURPHY^[15]提出,并在生物医学、电力系统、控制、寿命预测等领域得到了广泛应用,但在用于滚动轴承故障诊断还有待探索。与KHANAM等建立完整的轴承系统非线性动力学模型不同,论文将故障轴承的振动信号时域波形分为故障冲击振动和正常振动两部分。建立了轴承系统单自由度质量-阻尼-弹簧非线性振动模型,将冲击振动视为该模型的脉冲激励响应;将正常振动近似视为线性模型,对两种状态分别建立卡尔曼滤波器,并应用开关卡尔曼滤波算法进行处理。判断出每个时刻状态监测数据最可能的状态,进而滤除噪声并识别出冲击响应成分,有效提高了信号的信噪比。利用滚动轴承仿真故障信号和美国辛辛那提大学智能系统维护中心(IMS)的轴承全寿命周期状态监测数据进行验证,有效提取了故障引起的脉冲冲击成分,表明所提方法的有效性。

1 卡尔曼滤波算法

1.1 线性卡尔曼滤波

线性卡尔曼滤波算法适用于随机线性离散系统的状态或参数估计,是一种线性最小方差估计。在卡尔曼滤波中,系统的状态用一个矢量来表示。系统的运行过程可看作状态转移过程。卡尔曼滤波要实现的功能是利用测量的状态值 Y_k 去估计隐藏在噪声中的系统状态 X_k 。

定义一个随机离散时间过程的状态矢量 $X_k \in \mathbf{R}$,则线性系统离散随机差分方程为

$$X_k = AX_{k-1} + W_k \quad (1)$$

式中, X_k 是 k 时刻的 $n \times 1$ 维系统状态矢量, n 是状态变量个数; X_{k-1} 是 $k-1$ 时刻系统状态矢量; A 是 $k-1$ 时刻至 k 时刻的 $n \times n$ 维一步状态转移矩阵; W_k 是 k 时刻的 $n \times 1$ 维过程激励噪声。

对 X_k 的测量满足线性关系,定义测量矢量 $Y_k \in \mathbf{R}$,则测量方程为

$$Y_k = HX_k + V_k \quad (2)$$

式中, Y_k 是 k 时刻的状态测量值; H 是 $1 \times n$ 维测量矩阵; V_k 是 k 时刻的测量噪声。

假设 W_k 、 V_k 是相互独立,正态分布的白色噪声,过程激励噪声协方差矩阵为 Q ,测量噪声协方差矩阵为 R ,即: $W_k \sim N(0, Q)$, $V_k \sim N(0, R)$ 。

卡尔曼滤波的主要过程如下。

状态一步预测

$$\hat{X}_k = AX_{k-1} \quad (3)$$

协方差一步预测

$$\hat{P}_k = AP_{k-1}A^T + Q \quad (4)$$

卡尔曼增益

$$K_k = \hat{P}_k H^T (H \hat{P}_k H^T + R)^{-1} \quad (5)$$

状态更新

$$X_k = \hat{X}_k + K_k (Y_k - H \hat{X}_k) \quad (6)$$

协方差更新

$$P_k = (I - K_k H) \hat{P}_k \quad (7)$$

式中, $\hat{X}_k$ 表示 k 时刻先验状态估计值,这是算法根据前次迭代结果(即上一次循环的后验估计值)做出的不可靠估计; $\hat{P}_k$ 表示 k 时刻的先验估计协方差,只要确定了初始的协方差 P_0 ,此协方差矩阵后续时刻的值都能递推出来,且只要初始协方差 $P_0 \neq 0$,它的取值对滤波效果影响很小,都能很快收敛; K_k

表示卡尔曼增益,由公式可知其也能在滤波前预先递推计算出来,对卡尔曼增益的确定是建立滤波模型的关键步骤之一,它能显著影响滤波的结果; $\mathbf{X}_k$, $\mathbf{X}_{k-1}$ 表示 k 时刻、 $k-1$ 时刻后验状态估计值,也就是要输出的该时刻最优估计值,这个值是卡尔曼滤波的结果; $\mathbf{P}_k$, $\mathbf{P}_{k-1}$ 表示 k 时刻、 $k-1$ 时刻的后验估计协方差。

1.2 开关卡尔曼滤波

实际中系统状态处于不断变化的过程中,为此提出一种开关卡尔曼滤波算法。首先分析系统各种可能存在的状态,并针对每种状态建立相应的卡尔曼滤波器。随后通过计算每时刻各状态的概率,进而分析出该时刻系统最可能所处的状态。开关卡尔曼滤波的计算过程如下。

依据贝叶斯估计理论,对于一个由 l 个卡尔曼滤波器描述的动态系统,模型变换概率

$$S_k^{ij} = \frac{\mathbf{Z}_{ij}^T \mathbf{S}_{k-1}^i}{\sum_{i=1}^l \mathbf{Z}_{ij}^T \mathbf{S}_{k-1}^i} \quad (8)$$

式中, S_k^{ij} 表示模型从 $k-1$ 时刻的模型 i 变换到 k 时刻的模型 j 的概率; S_{k-1}^i 表示 $k-1$ 时刻系统是模型 i 的概率; $\mathbf{Z}_{ij}$ 表示模型转移矩阵。

加权状态和协方差估计

$$\tilde{\mathbf{X}}_{k-1}^j = \sum_{i=1}^l S_k^{ij} \mathbf{X}_{k-1}^i \quad (9)$$

$$\tilde{\mathbf{P}}_{k-1}^j = \sum_{i=1}^l S_k^{ij} \{ \mathbf{P}_{k-1}^i + [\mathbf{X}_{k-1}^i - \mathbf{X}_{k-1}^j][\mathbf{X}_{k-1}^i - \mathbf{X}_{k-1}^j]^T \} \quad (10)$$

式中, $\mathbf{X}_{k-1}^i$ 表示 $k-1$ 时刻模型 i 的后验状态估计值; $\mathbf{P}_{k-1}^i$ 表示 $k-1$ 时刻模型 i 的后验估计协方差。将式(9)、(10)计算的加权状态和协方差代入到式(3)~(7)的滤波器工作过程中,可得每个模型对应的最优状态估计 $\hat{\mathbf{X}}_{k-1}^j$ 和协方差估计 $\hat{\mathbf{P}}_{k-1}^j$ 。

每个滤波器模型的似然估计计算如下

$$\mathbf{L}_k^i = N(\mathbf{V}_k^i; 0, \mathbf{C}_k^i) \quad (11)$$

其中测量残差

$$\mathbf{V}_k = \mathbf{Y}_k - \mathbf{H}\hat{\mathbf{X}}_k \quad (12)$$

残差协方差

$$\mathbf{C}_k = \mathbf{H}\hat{\mathbf{P}}_k\mathbf{H}^T + \mathbf{R} \quad (13)$$

则 k 时刻每个模型的概率

$$S_k^i = \frac{\mathbf{L}_k^i \sum_{i=1}^l \mathbf{Z}_{ij}^T \mathbf{S}_{k-1}^i}{\sum_{i=1}^l \left(\mathbf{L}_k^i \sum_{i=1}^l \mathbf{Z}_{ij}^T \mathbf{S}_{k-1}^i \right)} \quad (14)$$

更新的加权状态和协方差计算如下

$$\mathbf{X}_k = \sum_{i=1}^l S_k^i \mathbf{X}_k^i \quad (15)$$

$$\mathbf{P}_k = \sum_{i=1}^l S_k^i \{ \mathbf{P}_k^i + [\mathbf{X}_k^i - \mathbf{X}_k][\mathbf{X}_k^i - \mathbf{X}_k]^T \} \quad (16)$$

综上所述,论文应用开关卡尔曼滤波算法处理故障滚动轴承振动信号,辨识故障冲击成分,进而实现其故障诊断。所提方法流程图如图 1 所示。其中滤波器模型的建立如下节所述。

图 1 开关卡尔曼滤波故障诊断方法流程图

2 滤波器模型

已有的研究表明,当滚动轴承产生如点蚀、剥落、擦伤等表面损伤类故障时,滚动体滚过缺陷处会激发一个脉冲力,脉冲力为宽带信号能激起轴承系统的高频固有振动。一般情况下故障轴承的振动信号波形如图 2 所示。可知其主要由两种成分组成:一是幅值较高的高频衰减振动,二是幅值较低且波动轻微的正常振动。信号在两种成分间周期性动态变化。但实际中采集到的轴承振动信号往往含有很大的噪声,淹没两种信号成分。根据开关卡尔曼滤波的原理,可以建立两种滤波器模型,将高频衰减

图 2 故障轴承振动信号

振动视为系统冲击振动响应，将低幅值的正常振动视为线性模型，利用开关卡尔曼滤波算法便可滤除信号中的噪声，并识别出高频脉冲冲击振动，进而实现滚动轴承的故障特征提取。

2.1 基于正常轴承振动的滤波器模型

轴承的状态用振动加速度响应表示

$$X_1 = \ddot{x} \quad X_2 = \dot{X}_1 \quad (17)$$

式中， x 是系统的振动位移响应。则状态矢量为

$$\mathbf{X}(t) = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \quad (18)$$

轴承的正常振动幅值较低，波动较缓，从波形特征来考虑，将其视为线性模型。则此时的状态转移矩阵 $\mathbf{A}_1$ 为

$$\mathbf{A}_1 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (19)$$

根据文献[13]，系统的过程激励噪声是由一系列不可建模因素造成的，如赫兹接触力、载荷在有限个滚动体间传递导致的变刚度、轴承间隙、缺乏润滑膜等。过程噪声矩阵可由传递函数方法计算出。过程噪声矩阵 $\mathbf{Q}(k)$ 为

$$\mathbf{Q}(k) = \begin{bmatrix} E[x_1 x_1] & 0 \\ 0 & E[x_2 x_2] \end{bmatrix} \quad (20)$$

式中， $E(x_i x_i)$, $i=1 \sim 2$ 是均方误差，计算如下

$$E(x_i x_i) = \int_0^{T_s} \int_0^{T_s} g_i(u) g_i(v) E(W(u)W(v)) du dv \quad (21)$$

式中，权重函数 $g_i(\bullet) = L^{-1}(G_i(s))$, $i=1 \sim 10$ 。 $G_i(s)$ 是第 i 个状态指标的传递函数，分别计算如下

$$G(F_{\text{fault}}(s) \text{ to } X_1) = G_1(s) = \frac{1}{ms^2 + cs + k} \quad (22)$$

$$G(F_{\text{fault}}(s) \text{ to } X_2) = G_2(s) = \frac{1}{ms^2 + cs + k} \quad (23)$$

式中， F_{fault} 为故障引起的冲击力。

2.2 基于故障冲击振动的滤波器模型

将轴承简化为单自由度的质量-阻尼-弹簧模型，如图 3 所示。

图 3 滚动轴承振动模型

当滚动体滚过缺陷发生故障冲击时，简化的轴承系统的振动微分方程如下

$$m\ddot{x} + c\dot{x} + kx = F_{\text{fault}} \quad (24)$$

式中， m 为外圈及轴承座的等效质量， c 为等效阻尼， k 为等效刚度。

系统的状态空间模型为

$$\begin{bmatrix} \dot{X}_1 \\ \dot{X}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -\frac{k}{m} & -\frac{c}{m} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{F_{\text{fault}}}{m} \end{bmatrix} + \begin{bmatrix} W_1 \\ W_2 \end{bmatrix} \quad (25)$$

取采样间隔为 T_s ，则系统离散状态方程为

$$\begin{bmatrix} X_1(k+1) \\ X_2(k+1) \end{bmatrix} = \mathbf{A}_2 \begin{bmatrix} X_1(k) \\ X_2(k) \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{F_{\text{fault}}}{m} T_s \end{bmatrix} + \begin{bmatrix} W_1 \\ W_2 \end{bmatrix} \quad (26)$$

其中状态转移矩阵 $\mathbf{A}_2$ 为

$$\mathbf{A}_2 = \begin{bmatrix} 1 & T_s \\ -\frac{k}{m} T_s & 1 - \frac{c}{m} T_s \end{bmatrix} \quad (27)$$

2.3 测量方程

测量指标选为加速度 $\ddot{x}$ ，则测量矢量

$$\mathbf{Y}(t) = \ddot{x} \quad (28)$$

测量矩阵

$$\mathbf{H} = [0 \ 1] \quad (29)$$

测量误差 R 一般选取为轴承无故障时测量数据的方差。

2.4 初始值设定

模型转移矩阵

$$\mathbf{Z} = \begin{bmatrix} 0.999 & 0.001 \\ 0.001 & 0.999 \end{bmatrix} \quad (30)$$

状态转移概率的选取是基于系统趋向于保持原来状态的性质。即当 $i=j$ 时， $\mathbf{Z} \sim 1$ ， $i \neq j$ 时， $\mathbf{Z} \sim 0$ 。

初始模型概率

$$\mathbf{S}_0 = [0.5 \ 0.5] \quad (31)$$

这样选取是因为轴承刚开始旋转工作时，滚动体有可能恰好位于缺陷处，也有可能不在缺陷处。

初始状态

$$\mathbf{X}_0 = \mathbf{Y}(1) \quad (32)$$

即选取第一次测量值作为滤波的初始状态。

初始协方差矩阵

$$\mathbf{P}_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad (33)$$

3 仿真与试验验证

3.1 仿真验证

仿真外圈故障轴承振动信号，如图 4a 所示。为

了验证滤波器对不同信噪比情况下噪声的滤除效果,对图 4a 所示信号施加高斯白噪声使信号信噪比 (SNR) 分别为 10 dB 和 -10 dB, 如图 4b、4c 所示。

图 4 仿真故障轴承振动信号

对图 4b、4c 两组信号时域滤波处理结果如图 5 所示。分析图 5a 和图 5b 两组时域滤波结果可以看出, 开关卡尔曼滤波能有效地滤除掉噪声, 并识别出冲击成分。从图 6a 和图 6b 中对信号成分的判断可以看出, 噪声干扰大时, 对冲击存在时间段的判断缩短, 与实际有较大偏差。可见若噪声干扰大, 在滤波过程中会把冲击振动后期幅值较低的一些高频振动当作噪声处理掉, 从而导致对状态的误判断。但对比图 5a 和图 5b 中冲击振动开始出现的时间可以看出, 所提方法对冲击发生的时刻判断基本正确, 而这在滚动轴承故障诊断中是比较重要的。表 1 和

图 5 时域滤波结果

表 2 列出了滤波前后 5 种时域量纲一指标值。可以看出滤波后各指标相比滤波前都有了较明显的变化, 表明滤波是有效的。

图 6 信号成分判断结果

表 1 开关卡尔曼滤波时域量纲一统计指标(SNR=10 dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.837 0	11.561 7	0.001 9	21.238 7	30.713 2
滤波后	2.420 1	11.782 5	0.002 1	28.514 4	64.496 5

表 2 开关卡尔曼滤波时域量纲一统计指标(SNR=-10dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.252 8	6.733 4	0.013 9	8.435 8	9.935 7
滤波后	2.634 5	16.775 0	0.003 9	44.193 8	79.238 2

为了论证所提开关卡尔曼滤波方法的优越性, 分别单独使用两种滤波器模型对信号进行处理, 结果如图 7、8 所示。从图 7 可以看出, 使用基于正常振动滤波器模型进行滤波对噪声的去除效果很好, 但其会将冲击成分也视作噪声并滤除掉, 不能用作故障特征提取。而对比图 8 可以看出使用基于脉冲冲击滤波器模型进行滤波可以保留信号中的脉冲振动成分, 但对噪声的滤除效果较差。表 3~6 分别列出了相应的时域量纲一指标值。从中可以看出信噪比为 -10dB 时使用基于正常振动滤波器模型滤波前后各指标值差异较大, 但因其未识别出脉冲, 不能表明其有效性。其余情况下各指标值滤波前后变化不大, 表明这些情况下滤波效果较差。表 7 对上述三种滤波方式滤波后信号的信噪比做了对比。理想情况下滤波后计算的信噪比应当与添加噪声时给定的信噪比接近, 表明恰好滤除了添加的噪声。从表 7 可以看出, 使用基于正常振动滤波器模型滤波后信号的信噪比均降低, 表明其对信号过度滤波, 将有用成分也当作噪声滤除掉, 与图 7 所示结果一致。而使用基于脉冲冲击模型滤波后信噪比增加, 表明其对信号欠滤波, 未能有效滤除噪声, 与图 8 所示

结果一致。综合上述分析可以得出结论，所提方法综合了两种模型的优势，具有良好的滤波及脉冲识别效果。

图 7 基于正常振动模型滤波结果

图 8 基于故障冲击振动模型滤波结果

表 3 正常振动模型滤波时域量刚一统计指标(SNR=10 dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.850 2	11.430 1	0.001 9	21.147 5	30.965 8
滤波后	2.110 7	11.106 3	0.000 1	23.441 7	39.576 6

表 4 正常振动模型滤波时域量刚一统计指标(SNR=-10 dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.269 0	7.063 2	0.015 3	8.963 4	10.685 3
滤波后	1.666 7	37.336 6	0.000 3	62.227 4	77.124 3

表 5 冲击振动模型滤波时域量刚一统计指标(SNR=10 dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.833 8	11.783 3	0.002 1	21.680 6	31.500 2
滤波后	1.955 5	11.980 4	0.002 1	23.427 7	36.110 3

表 6 冲击振动模型滤波时域量刚一统计指标(SNR=-10 dB)

指标	波形因子	峰值因子	峭度因子	脉冲因子	裕度因子
滤波前	1.265 5	7.311 9	0.014 3	9.253 4	10.962 4
滤波后	1.320 5	8.010 2	0.004 3	10.577 1	12.763 9

表 7 滤波前后信号信噪比

滤波方式	所提方法	基于正常振动模型	基于冲击振动模型
滤波前/dB	10	8.024 1	-9.893 0
滤波后/dB	-10	-9.603 9	-23.556 2

3.2 试验验证

本文采用美国辛辛那提大学智能系统维护中心(IMS)的滚动轴承全寿命周期加速轴承性能退化试验数据进行验证。试验台和传感器布置如图 9、图 10 所示。旋转轴由 4 个 Rexhord ZA-2115 双列滚动轴承支撑，每个轴承的轴承座上均安置传感器并同时采集数据。试验时每隔 10 min 采集一次数据，每次采样 1 s，采样率 20 kHz。在一次试验中，测量了四个轴承的振动加速度数据，每个轴承得到 984 组数据，其中轴承 1 在试验结束后观察到外圈故障。因此后续选取轴承 1 的数据进行分析。

图 9 试验台示意图

图 10 传感器安装示意图

在进行滤波之前，要确定测量误差参数。选取 100 组轴承前期正常工作阶段的状态监测数据，计算其方差和标准差的均值。方差值可用作缺陷早期阶段滤波的测量误差，标准差可用作缺陷晚期阶段滤波的测量误差。这样选取是因为在缺陷故障较大时，引起的振动冲击较大，可能导致传感器与轴承座接触不稳，加大测量误差。

图 11 展示了故障轴承 1 振动信号原始波形。可以看出测量的信号中存在明显的噪声。利用所提方法处理该信号，得到的时域滤波结果如图 12 所示。

相比于原始测量信号,滤波后的结果变得干净且冲击成分更为明显。图13展示了对信号成分的判断结果。可以看出每时刻判断出的信号成分状态均符合实际。

图11 轴承1振动信号

图12 时域滤波结果

图13 信号成分判断结果

同时为了论证所提开关卡尔曼滤波方法的优越性,分别单独使用前述两种滤波器模型对信号进行处理,结果分别如图14、15所示。结果同仿真分析一致,使用基于正常振动滤波器模型滤波会对信号过度滤波,将冲击振动成分也滤除掉;而使用基于脉冲冲击模型滤波则未能有效滤除信号中的噪声成分。

图14 基于正常振动模型滤波结果

图15 基于故障冲击振动模型滤波结果

4 结论

(1) 本文提出了一种基于开关卡尔曼滤波算法的滚动轴承故障特征提取方法。针对故障轴承振动信号中故障冲击振动与正常振动两种确定性成分,分别建立相应的卡尔曼滤波器,随后使用开关卡尔曼滤波算法对振动信号进行滤波与状态识别。与使用单一的滤波器模型相比,所提方法保留了有用的冲击成分,并能准确识别染噪信号中的脉冲冲击,可以有效地应用于滚动轴承故障诊断。

(2) 开关卡尔曼滤波算法可以在每个采样点进行滤波及状态估计,响应快,实时性好。因此,在工程实际中具有一定应用价值。此外,滤波器模型参数对滤波结果有一定影响,如何自适应优化模型参数,可作为下一步研究工作的重点。

参考文献

- [1] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [2] CUI Lingli, HUANG Jinfeng, ZHANG Feibin. Quantitative and localization diagnosis of a defective ball bearing based on vertical-horizontal synchronization signal analysis[J]. IEEE Transactions on Industrial Electronics, 2017, 64(11): 8695-8705.
- [3] 贺王鹏, 訾艳阳, 陈彬强, 等. 周期稀疏导向超小波在风力发电设备发电机轴承故障诊断中的应用[J]. 机械工程学报, 2016, 52(3): 41-48.
HE Wangpeng, ZI Yanyang, CHEN Binqiang, et al. Periodic sparsity oriented super-wavelet analysis with application to motor bearing fault detection of wind turbine[J]. Journal of Mechanical Engineering, 2016, 52(3): 41-48.
- [4] CUI Lingli, WU Na, MA Chunqing, et al. Quantitative fault analysis of roller bearings based on a novel matching pursuit method with a new step-impulse dictionary[J]. Mechanical Systems and Signal Processing, 2016, 68-69: 34-43.
- [5] CUI Lingli, MA Chunqing, ZHANG Feibin, et al. Quantitative diagnosis of fault severity trend of rolling element bearings[J]. Chinese Journal of Mechanical Engineering, 2015, 28(6): 1254-1260.
- [6] JIANG Guoqian, XIE Ping, WANG Xiao, et al. Intelligent

- fault diagnosis of rotary machinery based on unsupervised multiscale representation learning[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1314-1324.
- [7] 刘东东, 程卫东, 万广通. 基于故障特征趋势线模板的滚动轴承故障诊断[J]. 机械工程学报, 2017, 53(9): 83-91.
- LIU Dongdong, CHENG Weidong, WAN Guangtong. Bearing fault diagnosis based on fault characteristic trend template [J]. Journal of Mechanical Engineering, 2017, 53(9): 83-91.
- [8] AHMED H O A, WONG M L D, NANDI A K. Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features[J]. Mechanical Systems & Signal Processing, 2018, 99: 459-477.
- [9] SONG Liuyang, WANG Huaqing, CHEN Peng. Step-by-step fuzzy diagnosis method for equipment based on symptom extraction and trivalent logic fuzzy diagnosis theory[J]. IEEE Transactions on Fuzzy Systems, 2018, doi: 10.1109/TFUZZ.2018.2833820.
- [10] SONG Liuyang, WANG Huaqing, CHEN Peng. Vibration-based intelligent fault diagnosis for roller bearings in low-speed rotating machinery[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(8): 1887-1899.
- [11] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering Transactions, 1960, 82: 35-45.
- [12] KHANAM S, TANDON N, DUTT J K. Fault identification of rolling element bearings from vibration signals: An application of Kalman and H^∞ Filters[C]// 10th International Conference on Vibrations in Rotating Machinery, September 11-13, 2012, Woodhead, London: IMechE, 2012: 703-713.
- [13] KHANAM S, DUTT J K, TANDON N. Extracting rolling element bearing faults from noisy vibration signal using Kalman filter[J]. Journal of Vibration & Acoustics, 2014, 136(3): 031008.
- [14] KHANAM S, TANDON N, DUTT J K. A system dynamic approach to bearing fault identification with the application of Kalman and H-infinity filters[J]. Journal of Vibration & Control, 2014, 22(13): 3022-3056.
- [15] MURPHY K P. Switching Kalman filters[J]. International Journal of Control, 1998, 75(16): 1269-1281.
-
- 作者简介: 崔玲丽(通信作者), 女, 1976 年出生, 博士, 教授, 博士研究生导师。主要研究方向为系统动力学模型及设备故障机理、先进信号处理方法、智能诊断与寿命预测技术。
E-mail: cuilingli@bjut.edu.cn
- 王鑫, 男, 1994 年出生, 博士研究生。主要研究方向为机械故障诊断, 剩余使用寿命预测。
E-mail: wang229xin@163.com
- 王华庆, 男, 1973 年出生, 博士, 教授, 博士研究生导师。主要研究方向为机械装备健康监测及故障智能诊断、信号处理与特征提取。
E-mail: hqwang@mail.buct.edu.cn