

面向轴承寿命预测的特征评估与模型优化^{*}

柏林, 闫康, 刘小峰

(重庆大学机械传动国家重点实验室 重庆, 400044)

摘要 针对滚动轴承剩余寿命预测中的特征评估及模型优化问题,提出了面向轴承寿命的特征评估与模型优化的方法。该方法在轴承特征进行单调性与敏感性评估的基础上,对轴承运行状态跟踪能力进行量化评估,进而筛选出表征轴承性能退化的多维特征集。为了减少多维特征集之间相关冗余信息对寿命预测的影响,采用相似近邻传播(affinity propagation,简称 AP)聚类方法对多维特征集进行聚类和筛选。为了统一描述 AP 聚类后的特征对轴承退化状态的表征信息,采用自组织神经网络(self-organizing feature map,简称 SOM)构建轴承健康指数。最后,利用自适应混沌粒子群算法(adaptive chaos particle swarm optimization,简称 ACPSO)优化双指数模型预测轴承剩余寿命。试验表明,该方法可以准确描述轴承运行状态时期,并有效地预测了轴承的剩余寿命。

关键词 滚动轴承寿命预测; AP 聚类; 自组织神经网络; 自适应混沌粒子群; 双指数模型

中图分类号 TH17; TP18

引言

作为旋转机械的重要组成部件,滚动轴承的状态监测及剩余寿命预测具有重要的学术研究意义与工程实践价值。鉴于轴承故障物理模型的不确定性,基于数据驱动的轴承寿命预测方法随着数据处理及智能信息技术的发展,其应用越来越广泛。基于数据驱动的寿命预测方法的关键在于状态特征的敏感评估、特征约简及寿命预测模型优化三个方面。针对提取敏感特征,申中杰等^[1]以相对方根均值(relative root mean square,简称 RRMS)作为轴承性能衰退评估指标,运用相关分析选取敏感特征,有效预测出轴承的剩余寿命,但当轴承运行工况发生改变 RRMS 是否还能准确对轴承状态进行评估无法考证。Ali 等^[2]对轴承振动信号进行经验模态分解并计算其能量熵,通过数学推导分析确定如何选取最敏感的固有模态函数(intrinsic mode function,简称 IMF),并利用神经网络进行轴承故障诊断,取得良好效果。在轴承寿命预测中,往往组建多维特征集,但多维特征集存在“维数灾难”。王奉涛等^[3]采用核主元分析(kernel principal component analysis,简称 KPCA)对高维特征集进行降维,并采用

威布尔比例故障率模型(weibull proportional hazard model,简称 WPHM)的协变量进行可靠性评估和剩余寿命预测,效果良好。何群等^[4]采用 PCA 进行多特征降维,并采用多变量极限学习机进行了轴承寿命的预测。这些降维方法只是单纯的数学运算进行信息再提取,没有考虑到轴承运行的实际工况, SOM 算法核心思想就是将最开始的正常轴承运行状态进行最优神经元权值的训练,然后将全寿命样本测试得到具有实际物理意义的健康指数。

文中考虑到不同型号的轴承在不同工况下运转得到的振动信号有所差别,单一确定的特征对轴承运行状况描述欠佳,故对不同轴承特征进行单调性与敏感性评估,量化轴承运行状态跟踪能力,筛选最具表现轴承运行状况的多维特征集,为减少多维特征集中相关冗余信息对寿命预测的影响,利用多维特征集之间的相似性进行 AP 聚类,选择各类跟踪能力最好的(即最佳描述轴承状态的特征)进行健康指数构建。健康指数构建采用 SOM 最小匹配距离的多特征融合降维方法,可以有效地表征轴承运行状态。文献^[5]指出,轴承从衰退期至失效期的运行状态可以近似看作是一种指数形式的增长, ACPSO 算法思想简单,求解速度快,采用自适应混沌可以最有效的求解全局最优解,故采用 ACPSO 算法优化

^{*} 国家自然科学基金资助项目(51475052;51675064);中央高校基本业务费资助项目(106112016CDJZR115502);博士后基金资助项目(2016T90833;2015M582519)
收稿日期:2018-01-22;修回日期:2018-05-09

双指数模型的参数,并利用该模型去预测轴承剩余寿命,所得结果验证了该方法的适用性和稳定性。

1 特征敏感性评估

提取对性能衰退敏感的特征对准确预测轴承剩余寿命尤为重要,传统上对于轴承性能衰退特征的选择存在主观选择的盲目性及拼合的随意性。对于滚动轴承性能退化的演化趋势,笔者综合考虑了演化趋势的单调性和敏感性,定义了敏感性的量化指标,对轴承信号特征的性能退化的跟踪能力进行表征,具体实施步骤如下。

1) 提取表1中轴承振动信号特征。

表1 轴承信号特征提取

Tab. 1 Feature extraction from bearing signal

类型	特征
时域	F_1 :峰值; F_2 :均值; F_3 :绝对平均值; F_4 :方差; F_5 :均方值; F_6 :均方根值; F_7 :峭度指标; F_8 :裕度指标; F_9 :脉冲指标; F_{10} :波形指标; F_{11} :峰值指标
频域	$F_{12} \sim F_{24}$:见文献[6]
时频域	$F_{25} \sim F_{32}$:8个EMD分解IMF的能量
三角函数	F_{33} : S_1 ; F_{34} : S_2

三角函数特征分别是反双曲余弦的标准差(S_1)及反双曲正弦的标准差(S_2),其公式如下。

$$\begin{cases} S_1 = \sigma[\log(x_i + \sqrt{x_i^2 - 1})] \\ S_2 = \sigma[\log(x_i + \sqrt{x_i^2 + 1})] \end{cases} \quad (1)$$

2) 对所有特征进行单调性和敏感性评价,计算特征 F_i 描述性能退化趋势 φ_i 的单调性统计值为

$$O_i = \sum_{n_1=1}^{N-1} \sum_{n_2=n_1+1}^N \text{sign}(\varphi_i(n_2) - \varphi_i(n_1)) \quad (2)$$

其中: $\varphi_i(n_1)$ 和 $\varphi_i(n_2)$ 分别为特征曲线 φ_i 在 n_1 和 n_2 时刻对应的特征值; $\text{sign}()$ 为符号函数; N 为特征 F_i 描述特征演化趋势曲线 φ_i 观测点总数。

特征 F_i 描述特征演化趋势曲线的单调性和敏感性水平分别为

$$\alpha_i = \frac{O_i}{N(N-1)/2} \quad (3)$$

$$\beta_i = \text{median}\left(\frac{\varphi_i(n_2) - \varphi_i(n_1)}{\varphi_i(1)(d(n_2) - d(n_1))}\right) \quad (4)$$

其中: $\text{median}()$ 为求中值函数; $\varphi_i(1)$ 为正常状态特征值; $d(n_1)$ 和 $d(n_2)$ 分别为 n_1 及 n_2 时刻滚动轴承退化的严重程度;曲线 $d(n_N)$ 用轴承特征均方根值进行替换。

3) 综合考虑性能退化的单调性和灵敏性,量化

各特征的性能退化跟踪能力为

$$T_i = [1 + e^{-10(\alpha_i - 0.5)}]^{-1} [1 + e^{-10(\beta_i - 0.5)}]^{-1} \quad (5)$$

2 特征约简

2.1 基于AP聚类的特征去冗余

由于通过跟踪能力获得的多维特征集彼此之间存在相关冗余信息会对预测轴承寿命的结果欠佳,AP聚类将多维特征集作为聚类的候选项,利用跟踪能力筛选出的 M 个特征的相似性进行聚类,该算法引入2个参数吸引度 $R(i,k)$ 和归属感 $A(i,k)$,计算每个特征的吸引度 R 和归属感 A ,公式如下

$$R(i,k) = S(i,k) - \max\{A(i,j) + S(i,j)\} \quad (j \in \{1,2,\dots,M, j \neq i,k\}) \quad (6)$$

$$A(i,k) = \min\{0, R(k,k) + \sum_j \max[0, R(i,k)]\} \quad (j \in \{1,2,\dots,M, j \neq i,k\}) \quad (7)$$

式(6)中 $S(i,j)$ 代表特征 F_i 与 F_j 之间的相似程度,当达到迭代次数或迭代收敛时,通过 $R(k,k) + A(k,k)$ 的值来判断是否为聚类中心,详细AP聚类算法及参数设置参见文献[7],通过AP聚类之后,可以将具有相关信息的特征组成一类,选取每类跟踪能力最好的特征进行后续SOM融合降维获得轴承健康指数。

2.2 基于SOM的特征融合降维

SOM算法通过正常状态时期的轴承特征进行训练获得输出神经元的权值矢量,再计算全寿命测试样本与每一个权值矢量欧式最小距离,该距离则是具有物理意义的轴承状态健康指数,相对于单纯的数学降维具有更为真实的效果,SOM可将任意维数的输入模式以拓扑有序的方式变换到一维或二维的离散空间上,这种变换称为特征映射,用 Φ 表示。设置 $\mathbf{P}_i(n)$ 为输入向量(即训练样本), $\mathbf{P}_i(n) = (F_{i1}(n), F_{i2}(n), \dots, F_{iN}(n))^T$; $\mathbf{W}_i(n)$ 为权值向量, $\mathbf{W}_i(n) = (w_{i1}(n), w_{i2}(n), \dots, w_{iN}(n))^T$; $i = 1, 2, \dots, n$; N 为训练样本维数;迭代次数为 K 。将AP聚类之后的特征集通过SOM网络获得获胜神经元权值矢量,测试样本 $\mathbf{Q}_i(p) = (F_{i1}^*(p), F_{i2}^*(p), \dots, F_{iN}^*(p))^T$,计算测试样本到训练样本权值矢量的欧式距离,获得融合最小匹配距离 I (即轴承健康指数)的计算公式如下

$$I = \{\min y_1, \min y_2, \dots, \min y_p\} \quad (8)$$

$$y_1 = \left\{ \sum_{j=1}^N \|Q_{ij}(1) - w_{ij}(1)\|^2, \sum_{j=1}^N \|Q_{ij}(1) - \right.$$

$$y_p = \left\{ \sum_{j=1}^N \|Q_{ij}(p) - \omega_{ij}(1)\|^2, \sum_{j=1}^N \|Q_{ij}(p) - \omega_{ij}(2)\|^2, \dots, \sum_{j=1}^N \|Q_{ij}(p) - \omega_{ij}(n)\|^2 \right\}$$

具体方法步骤参见文献[8],通过 SOM 获得了描述轴承运行状态的健康指数。

3 自适应混沌粒子群算法优化双指数模型

PSO 算法旨在寻求粒子(粒子为文中模型参数 a, b, c, d) 最优解,由于 PSO 算法易陷入局部最优解,从而导致拟合双指数模型参数出现较大误差,对后续预测寿命效果不佳,故将自适应混沌引入 PSO 算法中。在算法初期使用较大的惯性权重,具有较强的全局搜索能力,后期采用较小的惯性权重提高局部发掘能力,自适应惯性系数 ω 变化公式为

$$\omega = (\omega_{\max} - \omega_{\min}) \exp(-(\tau \times k / K_{\max})^2) + \omega_{\min} \quad (9)$$

其中: $\omega_{\max} = 0.9, \omega_{\min} = 0.4; k$ 为当前迭代次数; K_{\max} 为最大迭代次数;经验值 τ 一般在 $[20, 55]$ 内取值。

由于混沌 Logistic 模型形式简单,计算复杂度低,且当控制参数为 4 时趋向满映射,分布最均匀,已经满足 PSO 算法跳出局部最优解的需求,故文中选择混沌 Logistic 模型,混沌 Logistic 模型如下

$$x_{n+1} = 4x_n(1 - x_n) \quad (10)$$

其中: $n = 0, 1, \dots$ 。

将 x_{n+1} 替换粒子速度更新公式随机数 rand,最终的 ACPSO 迭代公式为

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 x_{n+1} (p_{id}^k - x_{id}^k) + c_2 x_{n+1} (p_{gd}^k - x_{id}^k) \quad (11)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (12)$$

其中: $d \in \{1, 2, \dots, D\}, D$ 为搜索空间的维数; c_1 和 c_2 为学习因子,一般设置为 2。

用均方误差值作为适应度函数,公式为

$$y^* = \frac{1}{N} \sum_{i=1}^N (y_i - Y_i)^2 \quad (13)$$

其中: y_i, Y_i 分别表示第 i 个健康指数点的实际值和双指数模型拟合值。

双指数模型表述如下

$$Y = ae^{bt} + ce^{dt} \quad (14)$$

其中: Y 为双指数模型拟合值; t 为轴承衰退时间点; a, b, c, d 为模型参数。

通过多次迭代当衰退点之后的健康指数实际值与双指数模型拟合值的均方误差 y^* 达到最小,此时的粒子则为双指数模型参数的最优解,该双指数模型即为确定。

4 特征评估与模型优化

图 1 给出了面向轴承寿命预测的特征评估与模型优化方法流程图,具体步骤如下:

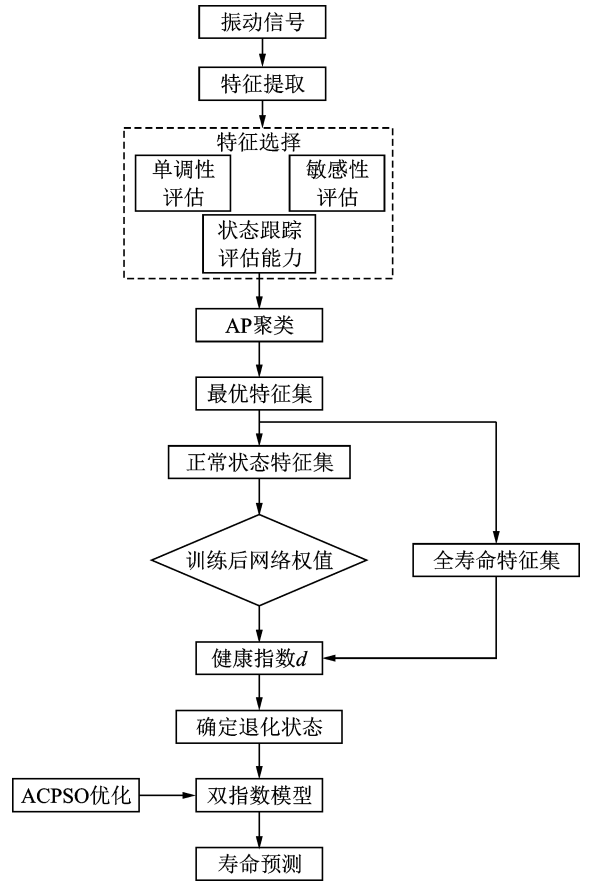


图 1 总体流程图

Fig. 1 General flow chart

- 1) 从原始振动信号提取 34 个特征(见表 1);
- 2) 对特征归一化及滑移平均^[9]处理;
- 3) 对特征进行单调性和敏感性评估,利用式(5)量化特征对轴承退化状态跟踪能力的评定,设定阈值为中间值 0.5,筛选超过阈值的特征组成多维特征集 M ;
- 4) 对多维特征集 M 进行 AP 聚类,筛选每类特征跟踪能力最好的构成最优特征集 N ;
- 5) 选取训练样本(全寿命周期的 1/4)^[10]进行 SOM 网络训练获取权值矢量,测试样本为全寿命最优特征集,通过 SOM 融合降维获得融合最小匹配距离 I (即健康指数);

6) 将6个训练轴承的健康指数绘制得到失效阈值;

7) 利用ACPSO优化双指数模型,将后续衰退时间带入参数确定好的公式(14),当模型曲线首次超过失效阈值,所对应的横坐标的时间点减去该轴承当前运行时间点,结果则为该轴承剩余使用寿命;

8) 对测试轴承寿命进行打分,打分公式为

$$S_c = \frac{1}{11} \sum_{i=1}^{11} B_i \quad (15)$$

$$B_i = \begin{cases} \exp(-\ln(0.5)(E_{ri}/5)) & (E_{ri} \leq 0) \\ \exp(+\ln(0.5)(E_{ri}/20)) & (E_{ri} > 0) \end{cases} \quad (16)$$

$$E_{ri} = \frac{L_{Ri} - L_{Pi}}{L_{Ri}} \times 100\% \quad (17)$$

其中: L_{Ri} , L_{Pi} , E_{ri} 和 B_i 分别为第 i 个测试数据的实际寿命、预测寿命、误差率和分数。

5 试验验证

为了验证文中方法的有效性,采用法国弗朗什-孔泰大学 FEMTO 研究所的 PRONOSTIA 实验平台^[11]下的滚动轴承全寿命公开数据,实验平台见图2,该振动信号采样频率为 25.6 kHz,数据采集卡(NIDAQCard-9174)每 10 s 采集一次数据,每次采集数据时长为 0.1 s,采集数据点 2 560 个,所有轴承工况见表 2。




图2 PRONOSTIA 试验台
Fig.2 PRONOSTIA test station

表2 轴承总体概况
Tab.2 General situation of bearing

运行状况	载荷/N	速度/ (r · min ⁻¹)	训练轴承	测试轴承
工况 1	4 000	1 800	轴承 1-2	轴承 3-7
工况 2	4 200	1 650	轴承 1-2	轴承 3-7
工况 3	5 000	1 500	轴承 1-2	轴承 3

以轴承 1-1 为例,提取轴承 34 个特征,采用步骤 3 处理,图 3 为所有特征的跟踪能力量化值。




图3 状态跟踪能力 T
Fig.3 Status tracking capability T

将特征集超过阈值的 25 个特征按照序号从 1~25 列出,采用步骤 4 处理,结果如表 3 所示。

表3 AP 聚类特征筛选
Tab.3 Feature selection of AP clustering

特征类	特征代号	优选特征
1	1, 2, 3, 4, 5, 6, 10, 11	6
8	7, 8, 9, 13, 16	8
12	12	12
14	14, 15	15
18	17, 18, 19, 20, 21, 22, 23	19
24	24, 25	25

由表 3 得到优选特征集 $N = \{F_6, F_8, F_{12}, F_{15}, F_{19}, F_{25}\}$,对 N 进行 SOM 融合降维,SOM 融合降维如图 4 所示。从图 4 中可以看出,初始轴承处于正常状态,随着轴承继续运行,健康指数开始呈现波动上升直至最后健康指数突然上升,轴承失效,说明 SOM 融合降维特征具有追踪轴承状态跟踪能力。按照步骤 6 进行所有训练轴承 SOM 融合降维,融合特征如图 5 所示。




图4 轴承 1-1 健康指数
Fig.4 Health index of bearing 1-1

从图 5 可以看出,训练轴承均在健康指数 I 在 0.9 处突然呈现急剧上升,表明轴承接近失效状态,故将训练轴承的失效阈值设为 0.9。




图 5 训练轴承健康指数

Fig. 5 Health index of training bearing

因步骤 7 对所有测试轴承进行寿命预测,退化阈值的选取采用轴承健康状态序列的 $\mu + 3\sigma$ (μ 为序列均值, σ 为序列标准差)^[12] 进行确定,健康指数超过退化阈值且保持连续多个点即可认定为初始退化点。以轴承 1-3 为例进行 SOM 特征融合降维,融合降维见图 6。图 6 中轴承的退化阈值 8 630 s 处超过退化阈值 $5.896 1 \times 10^{-4}$ ($\mu = 1.227 5 \times 10^{-4}$, $3\sigma = 4.668 5 \times 10^{-4}$) 且后续多点均超过,故 8 630 s 处为该轴承退化起始点。采用 ACP SO 进行优化双指数模型参数,以退化阈值开始拟合双指数模型,拟合之后接着进行后续寿命预测,当超过失效阈值 0.9 所对应的横坐标即为该轴承运行的截止时间,图 7 为轴承 1-3 的寿命预测图。

从图 7 中看出,当轴承运行到 23 540 s 时双指数模型曲线值超过失效阈值 0.9,说明轴承失效,以失效时间点 23 540 s 减去轴承当前时间点 18 020 s

得到结果为 5 520 s,说明轴承还可以运行 5 520 s,和实际寿命 5 730 s 较为接近,对所有测试轴承进行预测并轴承预测精度进行打分与文献[13]进行对比,所有对测试轴承的预测结果如表 4 所示。




图 6 轴承 1-3 健康指数

Fig. 6 Health index of bearing 1-3




图 7 轴承 1-3 寿命预测

Fig. 7 Life prediction of bearing 1-3

表 4 测试轴承寿命预测结果

Tab. 4 Life prediction results of testing bearings

测试轴承	当前时间/s	实际寿命/s	预测寿命/s	$E_{r1} / \%$	$E_{r2} / \%$	$E_{r3} / \%$
轴承 1-3	18 010	5 730	5 520	3.66	-1.04	37
轴承 1-4	11 380	339	860	-153.69	-20.94	80
轴承 1-5	23 010	1 610	2 040	-26.71	-278.26	9
轴承 1-6	23 010	1 460	1 430	2.05	19.18	-5
轴承 1-7	15 010	7 570	5 640	25.50	-7.13	-2
轴承 2-3	12 010	7 530	6 620	12.09	10.49	64
轴承 2-4	6 110	1 390	2 130	-53.24	51.80	10
轴承 2-5	20 010	3 090	2 250	27.18	28.80	-440
轴承 2-6	5 710	1 290	1370	-6.20	-20.93	49
轴承 2-7	1 710	580	1 040	-79.31	44.83	-317
轴承 3-3	3 510	820	690	15.85	-3.66	90
S_c				0.390 8	0.355 0	0.306 6
S_d				55.111 5	90.292 4	173.275 7

E_{r1} 为文中方法误差率; E_{r2}, E_{r3} 为文献[13]方法误差率; S_d 为所有预测寿命误差率的标准差

从表 4 中可以看出,文中方法通过式(15~17)得出的预测结果分数高于文献[13]得分,说明预测

效果优于文献[13]效果。尽管对于某些轴承预测误差大于其他两种方法,但是通过从所有轴承预测寿

命的误差率的标准差来看,文中方法对于轴承寿命的预测更具稳定性,精确度更高。

6 结束语

笔者提出一种量化特征对轴承性能退化描述的方法,通过该方法可以筛选具有代表性的最优特征。提出利用 AP 聚类和 SOM 算法结合对轴承特征进行评估,既可去除冗余信息又可具体描述轴承运行整体状态。采用 ACPSO 算法优化双指数模型,体现 ACPSO 算法的优势,精度与算法稳定性优于其他两种方法,该方法在工程实际中也可以实时监控,为工程应用提供了一个很好的思路。

参 考 文 献

- [1] 申中杰,陈雪峰,何正嘉,等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J]. 机械工程学报,2013,49(2):183-189.
SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine [J]. Journal of Mechanical Engineering, 2013, 49 (2):183-189. (in Chinese)
- [2] ALI J B, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89 (3):16-27.
- [3] 王奉涛,陈旭涛,柳晨曦,等. 基于 KPCA 和 WPHM 的滚动轴承可靠性评估与寿命预测[J]. 振动、测试与诊断, 2017,37(3):476-483.
WANG Fengtao, CHEN Xutao, LIU Chenxi, et al. Rolling bearing assessment and life prediction based on KPCA and WPHM [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37 (3):476-483. (in Chinese)
- [4] 何群,李磊,江国乾,等. 基于 PCA 和多变量极限学习机的轴承剩余寿命预测[J]. 中国机械工程,2014,25 (7):984-989.
HE Qun, LI Lei, JIANG Guoqian, et al. Residual life predictions for bearings based on PCA and MELM [J]. China Mechanical Engineering, 2014, 25 (7): 984-989. (in Chinese)
- [5] JIN X H, YI S, QUE Z J, et al. Anomaly detection and fault prognosis for bearing [J]. IEEE Transactions on Instrumentation & Measurement, 2016, 65 (9):2046-2054.

- [6] 董绍江. 基于优化支持向量机的空间滚动轴承寿命预测方法研究[D]. 重庆:重庆大学,2012.
- [7] GAN G, NG K P. Subspace clustering using affinity propagation[J]. Pattern Recognition, 2015, 48(4): 1455-1464.
- [8] 张全德,陈果,林桐,等. 基于自组织神经网络的滚动轴承状态评估方法[J]. 中国机械工程,2017,28(5):550-558.
ZHANG Quande, CHEN Guo, LIN Tong, et al. Condition assessment for rolling bearings based on SOM [J]. China Mechanical Engineering, 2017, 28 (5):550-558. (in Chinese)
- [9] 康守强,叶立强,王玉静,等. 基于 MCEA-KPCA 和组合 SVR 的滚动轴承剩余使用寿命预测[J]. 电子测量与仪器学报,2017,31(9):1365-1371.
KANG Shouqiang, YE Liqiang, WANG Yujing, et al. Remaining useful life prediction of rolling bearing based on MCEA-KPCA and combined SVR [J]. Journal of Electronic Measurement and Instrument, 2017, 31 (9):1365-1371. (in Chinese)
- [10] WANG D, TSE P W, GUO W, et al. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis [J]. Measurement Science & Technology, 2011, 22 (2):025102.
- [11] PATRICK N, RAFAEL G, KAMAL M, et al. PRO-NOSTIA: an experimental platform for bearings accelerated life test [C]//Proceedings of IEEE International Conference on Prognostics and Health Management. [S. l.]:IEEE,2012:1-8.
- [12] LI N, LEI Y, LIN J, et al. An improved exponential model for predicting remaining useful life of rolling element bearings [J]. IEEE Transactions on Industrial Electronics, 2015, 62(12):7762-7773.
- [13] HONG S, ZHOU Z, ZIO E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method [J]. Digital Signal Processing, 2014, 27(1):159-161.



第一作者简介: 柏林,1972年11月生,男,博士、教授、博士生导师。主要研究方向为智能测试理论与技术及虚拟仪器,智能控制与计算机协同监控。曾发表《Fault diagnosis of rolling element bearing using more robust spectral kurtosis and intrinsic time-scale decomposition》《Journal of Vibration & Control》2014, Vol. 22, No. 12)等论文。
E-mail: Bolin0001@aliyun.com