

DOI: 10.13382/j.jemi.2017.09.003

# 基于 MCEA-KPCA 和组合 SVR 的滚动轴承剩余使用寿命预测<sup>\*</sup>

康守强<sup>1</sup> 叶立强<sup>1</sup> 王玉静<sup>1</sup> 谢金宝<sup>1</sup> Mikulovich V I<sup>2</sup>

(1. 哈尔滨理工大学电气与电子工程学院 哈尔滨 150080; 2. 白俄罗斯国立大学 明斯克 220030)

**摘要:**为了准确预测滚动轴承的剩余使用寿命(RUL),提出一种多评价标准有效性分析(MCEA)、核主成分分析(KPCA)和组合支持向量回归(SVR)相结合的滚动轴承RUL预测方法。该方法对提取的特征计算每个评价标准的有效性得分,自适应地确定每个评价标准的权重,筛选出有效性总得分高于其整体平均值的特征,进一步利用KPCA去除已筛选特征之间的信息冗余,建立约简后的特征矩阵。将多个轴承约简后的特征分别作为SVR的输入,当前使用寿命与全寿命的比值p即RUL作为输出,建立多个SVR模型,并采用自适应的方法确定各模型的权重,最终构建组合SVR预测模型。最后,对与训练不同的轴承进行测试,将约简后特征输入到组合SVR预测模型中,预测轴承的p值,实验结果表明,所提方法可准确地对滚动轴承进行RUL预测。

**关键词:**滚动轴承;有效性分析;特征约简;剩余使用寿命预测

中图分类号: TN911.7; TH165.3 文献标识码: A 国家标准学科分类代码: 460.1520

## Remaining useful life prediction of rolling bearing based on MCEA-KPCA and combined SVR

Kang Shouqiang<sup>1</sup> Ye Liqiang<sup>1</sup> Wang Yujing<sup>1</sup> Xie Jinbao<sup>1</sup> Mikulovich V I<sup>2</sup>

(1. School of Electrical and Electronic Engineering, Harbin University of Science and Technology, Harbin 150080, China;  
2. Belarusian State University, Minsk 220030, Belarus)

**Abstract:** In order to predict the remaining useful life (RUL) of rolling bearing accurately, a RUL prediction method of rolling bearing based on multiple criterions effectiveness analysis (MCEA), kernel principal component analysis (KPCA) and combined support vector regression machine (SVR) is proposed. For extracted feature, the effectiveness score of each criterion can be calculated, and the weight of each criterion can be determined adaptively, the feature will be sifted when the effectiveness total score of which is greater than its overall average, and the KPCA is used to remove the information redundancy among the sifted features, then the reduced feature matrix is established. The reduced features of multiple bearings are used respectively as the input of the SVR, the ratio  $p$  of the bearing running time to the whole life time, namely RUL are used as the output, multiple SVR models are established. And the self-adaptive method is used to determine the weight of each SVR model, the combined SVR prediction model can be established at last. Finally, the bearing which is different from the training process is used for testing, the reduced features are used as the input of the combined SVR prediction model, the  $p$  value of the bearing is predicted. The experimental results show that the RUL of the rolling bearing can be predicted accurately by the proposed method.

**Keywords:** rolling bearing; effectiveness analysis; feature reduction; remaining useful life prediction

## 0 引言

当前,旋转机械在工业生产中被广泛应用,滚动轴承

作为旋转机械中的基础部件之一,其运行状态的好坏会对整台设备产生重要影响<sup>[1-3]</sup>。滚动轴承的剩余使用寿命(remaining useful life, RUL)是其受损程度的综合反映。因此,准确预测轴承的RUL对旋转机械的视情维修意义

重大<sup>[4]</sup>。

对轴承运行状态的预测已引起学者的广泛关注。文献[5]对能够表征滚动轴承退化趋势的特征进行预测,取得了较好的效果;文献[6]预测特征在下一阶段的变化趋势并与可靠度模型相结合,实现了对轴承运行状态可靠度的预测。上述方法中,只进行特征变化趋势的预测并不能够直接预测出轴承的RUL,此外,在进行可靠度预测的同时也要考虑轴承的个体差异。本文对轴承的RUL进行预测,并对同工况、同型号条件下的不同轴承进行实验研究。

滚动轴承RUL预测与状态分类、状态评估相类似,需要提取振动信号的特征,众多学者已提出振动信号的时域统计指标、频域统计指标、包络谱特征、复杂度特征和时频特征等,特征约简方法也有很多报道<sup>[7-9]</sup>。文献[10]将相关性、单调性以及鲁棒性3个评价标准以凸组合的方式相结合,对轴承振动信号特征进行选择;文献[11]利用Pearson相关系数、Fisher判别率、散度矩阵、Margin width以及Kernel class separability对行星齿轮箱振动信号特征进行有效性分析,通过各特征之间的Pearson相关系数对特征之间进行相关性分析,最后基于ad hoc技术在特征的有效性和相关性之间取得平衡,实现了特征选择。文献[12]利用核主成分分析(kernel principal component analysis, KPCA)对轴承的特征进行降维处理,获得主要的信息成分。上述方法中,利用凸组合的方式进行特征选择时,采用人为方法确定每个评价标准的权重,具有一定的盲目性;在有效性分析的众多评价标准中,Margin width和Kernel class separability计算较为复杂,此外在ad hoc技术中参数的选取依然存在一定的盲目性。综上,本文利用Pearson相关系数、Fisher判别率、散度矩阵、单调性以及鲁棒性相结合的多评价标准有

$$ma_n = \begin{cases} \frac{1}{2n-1}(d_1 + \dots + d_{2n-1}), & 1 \leq n \leq (s-1)/2 \\ \frac{1}{s}(d_{n-(s-1)/2} + \dots + d_{n+(s-1)/2}), & (s-1)/2 < n < N_s - (s-1)/2 \\ \frac{1}{2(N_s - n) + 1}(d_{2n-N_s} + \dots + d_{N_s}), & N_s - (s-1)/2 \leq n \leq N_s \end{cases} \quad (1)$$

式中: $N_s$ 为去均值后的滚动轴承振动数据总个数, $s$ 为子矩阵内数据的个数,通常是奇数并且 $s < N_s$ , $d_n$ 为原始数据中第 $n$ 个监测值, $ma_n$ 为MA处理后的新数据点。

## 1.2 特征提取及处理

由于滚动轴承振动信号在一定尺度范围内具有分形特征,分形维数可有效地描述轴承振动信号的复杂性和不规则性,而基于数学形态学的分形维数的计算方法可得到更准确的结果。因此,本文采用滚动轴承的时域、频域和数学形态学分形维作为特征,具体如表1所示。

效性分析(multiple criterions effectiveness analysis, MCEA)来进行特征选择,采用自适应的方法确定每个评价标准的权重,筛选出有效性总得分大于平均值的 $L$ 个特征。对于选取的特征之间仍然存在相关性的问题,利用KPCA对其进行信息融合,降低特征之间的信息冗余。

在预测模型方面,文献[13]定义了滚动轴承的健康状态和6种退化状态,利用平滑预测算法将分类结果转化为RUL预测结果。文献[14]提出了基于健康状态评估的滚动轴承RUL预测方法,利用模糊c-均值对轴承不同性能退化模式进行评估,并建立对应的局部支持向量回归(support vector regression, SVR)预测模型,进行分段预测,有效地预测滚动轴承RUL。上述方法中,对轴承的健康与退化状态的划分,目前还缺乏严格的理论依据,同时,模糊c-均值的聚类效果会直接影响局部SVR模型的预测精度。本文利用多组轴承数据建立多个模型,采用自适应的方式确定每个模型的权重,最终建立组合的支持向量回归(combined SVR, CSVR)预测模型,实现滚动轴承的RUL预测。

综上,本文提出一种基于多评价标准的有效性分析结合核主成分分析(MCEA-KPCA)的特征约简方法,将多个单一SVR模型结合建立最终的CSVР预测模型,对滚动轴承当前使用寿命与全寿命的比值 $p$ 进行预测,最终实现滚动轴承的RUL预测。

## 1 特征提取与约简

### 1.1 原始数据预处理

对滚动轴承原始振动信号进行去均值处理,以此来抵消直流分量;然后利用滑移平均(moving average, MA)对信号进行平滑处理,如式(1)所示。

表1 特征说明表

Table 1 The features illustration

特征	特征名称
时域	均方根值,峰峰值,波形指标,峰值指标,脉冲指标,裕度指标,峭度指标 <sup>[15]</sup> , $f_i$ 和 $VH_i$ <sup>[14]</sup>
频域	重心频率,均方频率,均方根频率,频率方差 <sup>[16]</sup> ,频域指标 $F_1 - F_{13}^{[17]}$
形态学	数学形态学分形维数

表1中数学形态学分形维数是由滚动轴承振动信号经过 Hilbert 变换,再计算包络信号的数学形态学分形维数得到的,将其作为轴承状态特征。

特征处理包括两部分工作。

1)由于不同特征可能具有不同的数量级,本文利用式(2)对特征进行0~1的归一化处理。

$$Y = (Y_{\max} - Y_{\min})(X - X_{\min})/(X_{\max} - X_{\min}) + Y_{\min} \quad (2)$$

式中: $Y$ 为归一化结果,由于是在0~1进行归一化,所以 $Y_{\max} = 1, Y_{\min} = 0, X$ 为特征的值, $X_{\max}$ 为特征中的最大值, $X_{\min}$ 为特征中的最小值。

2)虽然原始数据已经通过MA进行数据预处理,但为了进一步提高特征的信噪比,再次利用式(1)对每个特征进行MA处理。以均方根值为例,MA得到的结果就是特征趋势项(图1中的实线),MA之前的特征减去特征趋势项得到特征剩余项,结果如图1所示。由图1可以看出,与MA前的特征相比,特征趋势项更加平滑,上升趋势更加明显,并且特征值全部处于0~1。

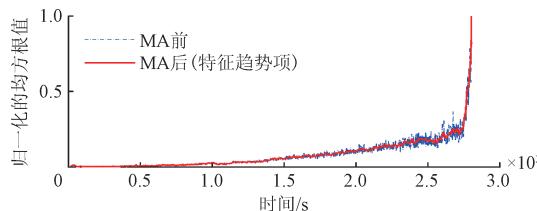


图1 MA 前后的均方根特征值对比

Fig. 1 The comparison of root mean square characteristic values before and after MA

### 1.3 特征约简

利用MCEA筛选特征结合KPCA对1.2节得到的特征趋势项进行约简。

由于利用单一的评价指标进行特征选择不能全面而准确地选择出有效特征,因此,采用多个评价标准进行有效性分析。首先,分别计算5个评价标准的有效性得分 $e$ ,即计算第 $k$ 个特征趋势项与轴承当前使用寿命和全寿命比值 $p$ 的Pearson相关系数得分 $e_{1k}$ ,第 $k$ 个特征趋势项的Fisher判别率得分 $e_{2k}$ 、散度矩阵得分 $e_{3k}$ 、单调性得分 $e_{4k}$ ,再利用第 $k$ 个特征的趋势项和剩余项计算鲁棒性得分 $e_{5k}$ ,将这5个评价标准定义为 $C_i (i=1,2,\dots,5)$ 。由于 $e_{1k}$ 至 $e_{5k}$ 分别具有不同的数量级,所以利用式(2)对 $e_{1k}$ 至 $e_{5k}$ 进行0到1的归一化。

然后,利用自适应的方法确定每个评价标准的权重 $\omega$ 。利用每个评价标准计算特征的有效性得分,将得分大于平均值的特征选出,并利用KPCA进行降维预测,得到该评价标准对应的平均绝对误差(MAE)、平均绝对百分误差(MAPE)、归一化均方误差(NMSE)和均方根误差

(RMSE)。这4种误差的和可衡量 $C_i$  EA-KPCA ( $i=1,2,\dots,5$ )特征约简的效果,这里当 $i=1$ 时 $C_1$  EA-KPCA 表示利用第1个评价标准,即采用Pearson相关系数特征有效性分析结合KPCA进行特征约简, $i$ 等于其他值时以此类推。由式(3)计算第 $i$ 个评价标准的权重:

$$\omega_i = \frac{1}{\sum_{i=1}^5 \frac{1}{MAE_i + MAPE_i + NMSE_i + RMSE_i}} \quad (3)$$

式中: $i=1,2,\dots,5$ 。

通过式(4)计算每个特征的有效性总得分:

$$E_k = \sum_{i=1}^5 \omega_i \cdot e_{ik} \quad (4)$$

式中: $k=1,2,\dots,K, K$ 表示特征总数。

求出所有特征的有效性总得分 $E_k$ 的整体平均值,将大于该平均值的 $E_k$ 所对应的第 $k$ 个特征筛选出来,作为特征有效性分析的结果。

最后,在选择有效特征的基础上,进一步利用KPCA对筛选出的特征进行特征信息融合,消除特征之间的冗余信息,至此完成特征约简。

## 2 构建 CSVR 预测模型

SVR是一种用于解决数据回归预测问题的机器学习算法,具有很好的泛化能力。针对单一SVR预测模型存在稳定性差的问题,对多个SVR进行某种合理的组合,根据每个SVR处理不同数据的预测效果确定权值,建立预测模型,理论上比单一SVR可获得更好的效果。将某滚动轴承约简后的特征作为SVR的输入, $p \in (0,1]$ 作为输出,利用果蝇优化算法(fruit fly optimization algorithm, FOA)对SVR模型的惩罚系数 $C$ 、径向基核函数宽度 $g$ 以及不敏感误差 $\varepsilon$ 进行寻优,建立SVR模型。以此类推,建立其他轴承的SVR模型,并自适应确定他们之间的权重系数,从而构建多轴承的CSVR预测模型。

以2个轴承作为训练对象,预测第3个轴承为例:首先利用第1个轴承建立 $SVR_1$ 模型,将第2个轴承的特征输入 $SVR_1$ 模型中,得到该轴承 $p$ 值,计算所求 $p$ 值与实际值间的4种误差和,即 $MAE_1 + MAPE_1 + NMSE_1 + RMSE_1$ 。然后再用第2个轴承建立 $SVR_2$ 模型,将第1个轴承的特征输入 $SVR_2$ 模型中,得到该轴承 $p$ 值,计算所求 $p$ 值与实际值间的误差和 $MAE_2 + MAPE_2 + NMSE_2 + RMSE_2$ 。最后利用式(5)求出 $SVR_1$ 模型和 $SVR_2$ 模型的权重 $\alpha_1$ 和 $\alpha_2$ 。

$$\alpha_j = \frac{1}{\sum_{j=1}^J \frac{1}{MAE_j + MAPE_j + NMSE_j + RMSE_j}} \quad (5)$$

式中: $j=1,2,\dots,J$ , $J$ 表示SVR模型的个数,当利用2个轴承训练时 $J=2$ 。

在建立 $SVR_j$ 模型并求出其对应的 $\alpha_j$ 后,根据式(6)可构建CSVR预测模型,基于此预测轴承3的RUL。

$$CSVR = \sum_{j=1}^J \alpha_j \cdot SVR_j \quad (6)$$

### 3 滚动轴承 RUL 预测方法及流程

滚动轴承RUL预测方法的流程图如图2所示。

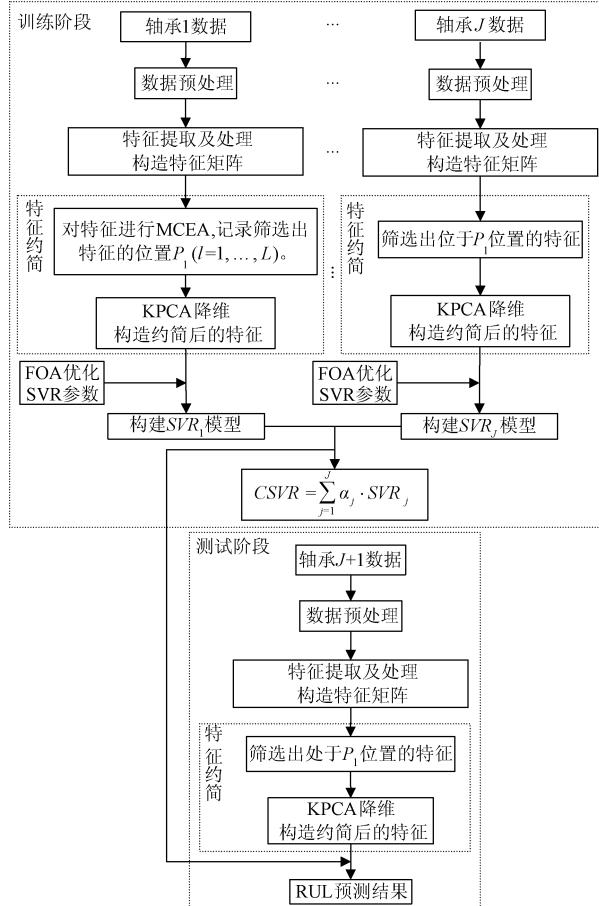


图2 滚动轴承RUL预测方法流程

Fig. 2 Flow chart of RUL prediction method of rolling bearing

具体流程:

1) 在对滚动轴承原始振动数据去除直流分量后,按照式(1)进行MA,然后按照表1提取出多个特征,对每个特征进一步进行MA处理得到特征趋势项,并按照式(2)对其进行归一化,构造特征矩阵。基于MCEA筛选出高于有效性总得分 $E_k$ 平均值所对应的第 $k$ 个特征,并记录其在特征矩阵中所处的位置 $P_l(l=1,2,\dots,L)$ ,进一步利用KPCA进行特征信息融合,构建约简后特征。

2) 基于约简后的特征,将 $p$ 作为SVR的输出,将

MAE、MAPE、NMSE及RMSE的和作为FOA的适应度函数,对SVR中的 $C,g$ 以及 $\varepsilon$ 的取值进行寻优,构建 $SVR_1$ 模型,同理构建其他SVR模型。

3) 根据式(5)求出各SVR模型的权重 $\alpha_j(j=1,2,\dots,J)$ ,再由式(6)构建CSVR预测模型,至此训练结束。

4) 在测试阶段,对第 $J+1$ 个滚动轴承采用与训练阶段相同的数据预处理、特征提取方法。将特征矩阵中处于 $P_l(l=1,2,\dots,L)$ 位置的 $L$ 个特征筛选出来,并利用KPCA去除信息冗余,建立约简后特征矩阵。将约简后特征输入到CSVR预测模型中预测 $p$ 值,实现预测滚动轴承的RUL。

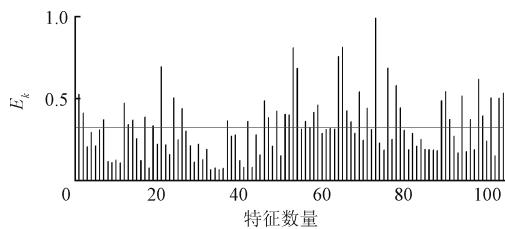
### 4 应用与分析

滚动轴承全寿命数据来自于PRONOSTIA试验台<sup>[18]</sup>,水平方向和垂直方向两个加速度传感器进行数据采集,分别每10 s记录一次数据,采样频率为25.6 kHz。本文将轴承编号1\_1和1\_3的全寿命周期数据作为训练,预测轴承1\_4的RUL,为避免数据中异常值的干扰,将每个数据的前部分点忽略,并对原始数据进行预处理,采用式(1)进行MA时,令 $s=11$ 。

根据表1分别对滚动轴承振动信号进行特征提取,由于试验台有水平方向和垂直方向两个传感器,再加上 $f_i$ 和 $VH_i$ 两个特征,所以有 $25 \times 2 + 2$ ,即52个特征。为了能够使特征具有一定的线性趋势,对上述52个特征取自然对数,这样又产生了新的52个特征。所以,本文共提取出104个特征并按照一定次序排列。

按照1.2节对轴承1\_1的特征进行特征处理,构造特征矩阵。分别利用单一评价标准筛选出有效性得分大于整体平均值的特征,通过KPCA降到3维,利用轴承1\_1预测轴承1\_3的 $p$ 值,并计算轴承1\_3的实际 $p$ 值与预测 $p$ 值间的MAE、MAPE、NMSE和RMSE值之和。5个评价标准对应的误差和 $MAE + MAPE + NMSE + RMSE$ 分别为1.3460、2.9996、3.3768、1.9841和4.9930,由式(3)可求得权重 $\omega_1 = 0.3578$ 、 $\omega_2 = 0.1605$ 、 $\omega_3 = 0.1426$ 、 $\omega_4 = 0.2427$ 和 $\omega_5 = 0.0964$ ,由公式(4)可得每个特征的 $E_k(k=1,2,\dots,104)$ 。特征矩阵中每个特征的 $E_k$ 如图3所示,整体平均值为0.3241,特征矩阵中共有44个特征的 $E_k$ 高于整体平均值,即 $L=44$ ,将这些特征筛选出来并记录下每个特征所处的位置 $P_l(l=1,2,\dots,44)$ 。这样就确定了在MCEA时需要被筛选出的特征,然后进一步利用KPCA对其进行降维处理,维数为3。将轴承1\_3的特征矩阵中处于 $P_l(l=1,2,\dots,44)$ 位置的特征筛选出来,利用KPCA降到3维,完成特征约简。

然后,将约简后的轴承1\_1的特征作为 $SVR_1$ 的输入,对应的 $p$ 作为输出建立 $SVR_1$ 模型;将约简后的轴承

图 3 特征矩阵中每个特征的  $E_k$ Fig. 3 The  $E_k$  of each feature in the feature matrix

$1\_3$  的特征作为  $SVR_2$  的输入, 对应的  $p$  作为输出建立  $SVR_2$  模型。以上两个模型中的参数均采用 FOA 进行优化,  $SVR_1$  中的  $C_1 = 236.0214$ ,  $g_1 = 85.0142$  和  $\varepsilon_1 = 0.0036$ ,  $SVR_2$  中的  $C_2 = 342.0345$ ,  $g_2 = 61.7129$  和  $\varepsilon_2 = 0.0041$ 。利用式(5)及(6)构建 CSVR 预测模型, 权重  $\alpha_1 = 0.5381$  和  $\alpha_2 = 0.4619$ 。

最后, 提取轴承  $1\_4$  的 104 个特征, 并对其进行处理构造特征矩阵。将处于  $P_l(l=1, 2, \dots, 44)$  位置的特征筛选出来, 再经过 KPCA 降到 3 维后, 建立约简后的特征矩阵。将约简后的特征输入到 CSVR 预测模型中, 预测轴承  $1\_4$  的  $p$  值, 实现对滚动轴承的 RUL 预测, 结果如图 4 所示。图 5~9 所示分别为基于第  $i$  个评价标准有效性分析结合 KPCA ( $C_i$ EA-KPCA,  $i=1, 2, \dots, 5$ ) 进行特征约简, 并利用 CSVR 模型预测对轴承  $1\_4$  的  $p$  进行预测的结果。图 10 和 11 所示为特征约简方法 MCEA-KPCA 分别结合单独建立的  $SVR_1$ 、 $SVR_2$  模型的预测结果。

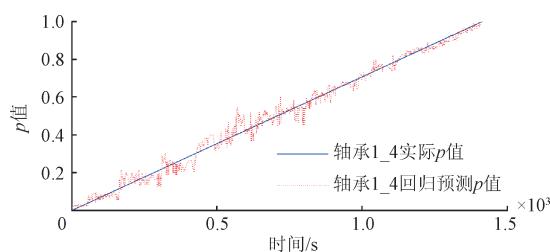
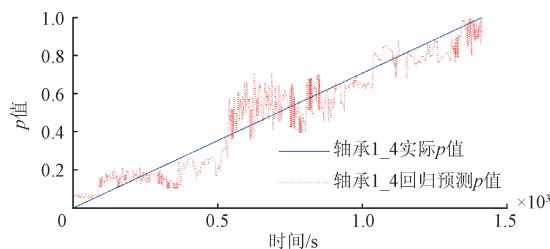
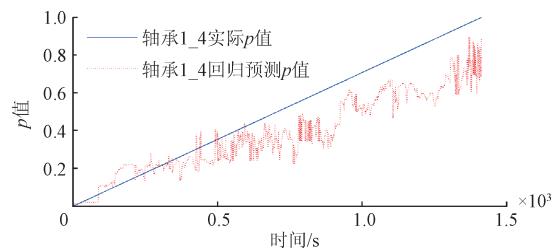
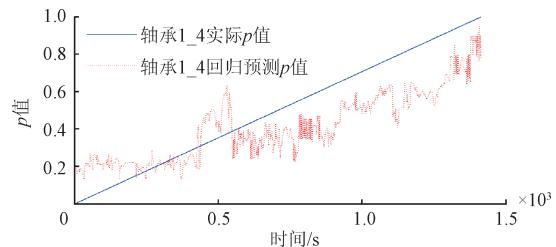
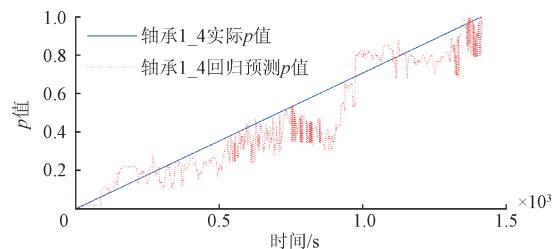
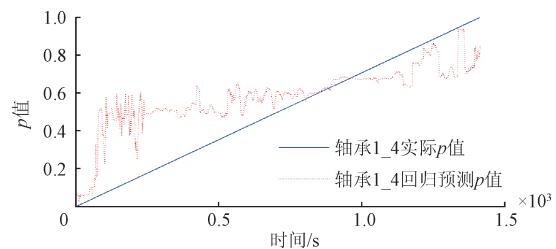


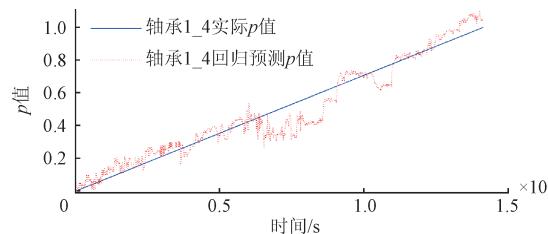
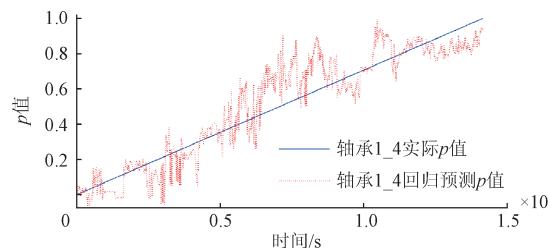
图 4 MCEA-KPCA 结合 CSVR 的 RUL 预测结果

Fig. 4 RUL prediction result of MCEA-KPCA and CSVR

图 5  $C_1$  EA-KPCA 结合 CSVR 的 RUL 预测结果Fig. 5 RUL prediction result of  $C_1$  EA-KPCA and CSVR图 6  $C_2$  EA-KPCA 结合 CSVR 的 RUL 预测结果Fig. 6 RUL prediction result of  $C_2$  EA-KPCA and CSVR图 7  $C_3$  EA-KPCA 结合 CSVR 的 RUL 预测结果Fig. 7 RUL prediction result of  $C_3$  EA-KPCA and CSVR图 8  $C_4$  EA-KPCA 结合 CSVR 的 RUL 预测结果Fig. 8 RUL prediction result of  $C_4$  EA-KPCA and CSVR图 9  $C_5$  EA-KPCA 结合 CSVR 的 RUL 预测结果Fig. 9 RUL prediction result of  $C_5$  EA-KPCA and CSVR

际值较为接近, 由图 5~9 可以看出, 基于单一的  $C_i$  EA-KPCA ( $i=1, 2, \dots, 5$ ) 进行特征约简, 并利用 CSVR 预测模型所得  $p$  的预测值与实际值偏差较大, 预测效果并不理想。由图 10 和 11 可以看出, 利用单独建立的  $SVR_1$  或  $SVR_2$  模型结合 MCEA-KPCA 特征约简来预测轴承的  $p$  值效果也不如基于 CSVR 模型(图 4)的效果好。对比图 4~11, 图 4 的预测效果最好, 也就是本文提出的基于

由图 4 可以看出, 所预测出的轴承  $1\_4$  的  $p$  值与实

图 10 MCEA-KPCA 结合 SVR<sub>1</sub> 的 RUL 预测结果Fig. 10 RUL prediction result of MCEA-KPCA and SVR<sub>1</sub>图 11 MCEA-KPCA 结合 SVR<sub>2</sub> 的 RUL 预测结果Fig. 11 RUL prediction result of MCEA-KPCA and SVR<sub>2</sub>

MCEA-KPCA 特征约简结合 CSVR 模型的方法预测效果最好, 各种方法的预测误差对比分析如表 2 所示。

表 2 不同方法的 *p* 值预测误差Table 2 The prediction errors of *p* value using different methods

预测方法	误差				误差和
	MAE	MAPE	NMSE	RMSE	
CSVR + C <sub>1</sub> EA-KPCA	0.065 5	0.323 8	0.076 0	0.079 6	0.544 9
CSVR + C <sub>2</sub> EA-KPCA	0.134 1	0.296 3	0.320 1	0.163 4	0.913 9
CSVR + C <sub>3</sub> EA-KPCA	0.153 7	1.187 6	0.370 1	0.175 7	1.887 1
CSVR + C <sub>4</sub> EA-KPCA	0.084 8	0.244 5	0.237 7	0.107 2	0.674 2
CSVR + C <sub>5</sub> EA-KPCA	0.205 7	1.294 3	0.444 6	0.192 6	2.137 2
SVR <sub>1</sub> + MCEA-KPCA	0.057 6	0.264 1	0.067 7	0.075 1	0.464 5
SVR <sub>2</sub> + MCEA-KPCA	0.063 7	0.212 5	0.192 5	0.072 4	0.541 1
CSVR + MCEA-KPCA	0.022 6	0.138 6	0.011 3	0.030 7	0.203 2

由表 2 可以看出, 基于 C<sub>1</sub>EA-KPCA, C<sub>2</sub>EA-KPCA 以及 C<sub>4</sub>EA-KPCA 特征约简的 RUL 预测效果要明显好于 C<sub>3</sub>EA-KPCA 和 C<sub>5</sub>EA-KPCA, 这恰好与评价标准 C<sub>3</sub> 及 C<sub>5</sub> 的权重较小相对应。相同预测模型的前提下, 与基于单一的 C<sub>i</sub>EA-KPCA ( $i = 1, 2, \dots, 5$ ) 特征约简相比, MCEA-KPCA 特征约简的 RUL 预测误差均为最小。相同特征约简方法的前提下, 与单一的 SVR 模型相比, CSVR 模型的 RUL 预测误差均为最小。证明了本文所提方法在 RUL 预测方面的优势。

## 5 结 论

针对滚动轴承 RUL 难以准确预测的问题, 在特征约简以及预测模型方面进行改进, 实现了滚动轴承的 RUL 预测, 为制定合理维修计划提供依据, 以减少经济损失和人员伤亡。

通过自适应的方法确定了每个特征评价标准的权重, 提出了基于 MECA-KPCA 的特征约简方法, 相比于单一评价标准有效性分析 C<sub>i</sub>EA-KPCA ( $i = 1, 2, \dots, 5$ ), 该特征约简方法在滚动轴承的 RUL 预测方面具有明显优势, 预测值与实际值间的 4 种误差以及误差和均为最小。

在训练过程中, 利用 2 个轴承分别建立 SVR<sub>1</sub> 和 SVR<sub>2</sub> 模型, 通过自适应的方式确定每个模型的权重, 进而建立 CSVR 预测模型, 实现同工况、同型号条件下不同滚动轴承的 RUL 预测, 比单一 SVR 模型预测的效果好, 预测值与实际值间的误差及误差和均最小。

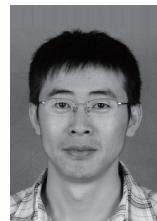
针对工程和实际应用中, 结合具体工况、环境, 依据一定的寿命标准, 实时在线评判具体某一个轴承的使用剩余寿命问题本文未能解决, 其也是下一步研究的重点。

## 参考文献

- [1] SOUALHI A, MEDJAHER K, ZERHOUNI N. Bearing health monitoring based on Hilbert-Huang transform, support vector machine and regression [J]. IEEE Transactions on Instrumentation & Measurement, 2015, 64(1): 52-62.
- [2] 康守强, 王玉静, 崔历历, 等. 基于 CFOA-MKHSVM 的滚动轴承健康状态评估方法[J]. 仪器仪表学报, 2016, 37(9): 2029-2035.
- [3] KANG SH Q, WANG Y J, CUI L L, et al. Health state assessment of a rolling bearing based on CFOA-MKHSVM method [J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 2029-2035.
- [4] 江星星, 李舜酩. 多共振频带自适应检测的轴承微弱故障诊断方法[J]. 电子测量与仪器学报, 2016, 30(4): 526-533.
- [5] JIANG X X, LI SH M. Bearing weak fault diagnosis method based on adaptive detection of multi-resonance bands [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(4): 526-533.
- [6] 张焱, 汤宝平, 熊鹏. 多尺度变异粒子群优化 MK-LSSVM 的轴承寿命预测[J]. 仪器仪表学报, 2016, 37(11): 2489-2496.
- [7] ZHANG Y, TANG B P, XIONG P. Rolling element bearing life prediction based on multi-scale mutation particle swarm optimized multi-kernel least square support vector machine[J]. Chinese Journal of Scientific

- Instrument, 2016, 37(11): 2489-2496.
- [5] DONG S J, YIN S R, TANG B P, et al. Bearing degradation process prediction based on the support vector machine and Markov model [J]. Shock and Vibration, 2014, 2014 (1-2): 1-15.
- [6] 陈昌. 基于状态振动特征的空间滚动轴承可靠性评估方法研究[D]. 重庆: 重庆大学, 2014: 43-48.
- CHEN CH. Reliability assessment method for space rolling bearing based on condition vibration feature [D]. Chongqing: Chongqing University, 2014: 43-48.
- [7] ZHAO M H, TANG B P, TAN Q. Bearing remaining useful life estimation based on time-frequency representation and supervised dimensionality reduction[J]. Measurement, 2016, 86(5): 41-55.
- [8] 黄良沛, 吴超威, 王靖. 小波包分析和BP神经网络在滚动轴承故障模式识别中的应用[J]. 电子测量技术, 2016, 39(4): 164-168.
- HUANG L P, WU CH W, WANG J G. Fault pattern recognition of rolling bearing using wavelet package analysis and BP neural network [J]. Electronic Measurement Technology, 2016, 39(4): 164-168.
- [9] 李鑫. 小波分析在滚动轴承故障信号处理中的应用[J]. 国外电子测量技术, 2013, 32(6): 65-67, 71.
- LI X. Wavelet applications in fault signal processing of rolling bearings [J]. Foreign Electronic Measurement Technology, 2013, 32(6): 65-67, 71.
- [10] ZHANG B, ZHANG L J, XU J W. Degradation feature selection for remaining useful life prediction of rolling element bearings[J]. Quality and Reliability Engineering International, 2016, 32 (2): 547-554.
- [11] LIU ZH L, ZUO M J, XU H B. Fault diagnosis for planetary gearboxes using multi-criterion fusion feature selection framework [J]. Proceedings of Institution of Mechanical Engineers Part C: Journal of Mechanical Engineering Science, 2013, 227(9): 2064-2076.
- [12] 刘韬, 陈进, 董广明. KPCA 和耦合隐马尔科夫模型在轴承故障诊断中的应用[J]. 振动与冲击, 2014, 33(21): 85-89.
- LIU T, CHEN J, DONG G M. Application of KPCA and coupled hidden Markov model in bearing fault diagnosis[J]. Journal of Vibration and Shock, 2014, 33(21): 85-89.
- [13] ALI J B, CHEBEL-MORELLO B, SAIDI L, et al. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network[J]. Mechanical Systems and Signal Processing, 2015, 56-57(5): 150-172.
- [14] LIU ZH L, ZUO M J, QIN Y. Remaining useful life prediction of rolling element bearings based on health state assessment [J]. Proceedings of Institution of Mechanical Engineers Part C: Journal of Mechanical Engineering Science, 2016, 230(2): 314-330.
- [15] LEI Y G, HE ZH J, ZI Y Y, et al. Fault diagnosis of rotating machinery based on multiple ANFIS combination with gas[J]. Mechanical Systems and Signal Processing, 2007, 21 (5): 2280-2294.
- [16] 杨慧斌, 滚动轴承故障诊断中的特征提取与选择方法[D]. 株洲: 湖南工业大学, 2011: 7-8.
- YANG H B. Features extraction and selection in rolling bearing fault diagnosis [D]. Zhuzhou: Hunan University of Technology, 2011: 7-8.
- [17] LEI Y G, HE ZH J, ZI Y Y, et al. A new approach to intelligent fault diagnosis of rotating machinery [J]. Expert Systems with Applications, 2008, 35 (4) : 1593-1600.
- [18] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. Pronostia: An experimental platform for bearings accelerated degradation tests [C]. Proceedings of IEEE International Conference on Prognostics and Health Management, 2012: 1-8.

## 作者简介



**康守强**(通讯作者),2011 年于白俄罗斯国立大学获得博士学位,现为哈尔滨理工大学教授、硕士生导师,主要研究方向为非平稳信号处理、机械故障诊断与状态评估技术。

E-mail:kangshouqiang@163.com

**Kang Shouqiang** (Corresponding author) received Ph. D. from Belarusian State University in 2011. Currently, he is a professor and M. Sc. supervisor in Harbin University of Science and Technology. His main research interests include non-stationary signal processing, machinery fault diagnosis and condition assessment technology.



**王玉静**,2016 年于哈尔滨工业大学获得博士学位,现为哈尔滨理工大学副教授、硕士生导师,主要研究方向为非平稳信号处理、机械故障诊断与状态评估技术。

E-mail:mirrorwyj@163.com

**Wang Yujing** received Ph. D. from Harbin Institute of Technology in 2016. Now she is an associate professor and M. Sc. supervisor in Harbin University of Science and Technology. Her main research interests include non-stationary signal processing, machinery fault diagnosis and condition assessment technology.