

DOI: 10.11830/ISSN.1000-5013.202012025



采用 EEMD-KPCA 处理的 IHHO-LSSVM 滚动轴承寿命预测模型

胡启国¹, 何奇¹, 曹历杰²

(1. 重庆交通大学 机电与车辆工程学院, 重庆 400074;

2. 川庆钻探工程公司 安全环保质量监督检测研究院, 四川 广汉 618300)

摘要: 为提高滚动轴承剩余寿命预测精度,提出一种基于集合经验模态分解-核主成分分析(EEMD-KPCA)和改进的哈里斯鹰优化-最小二乘支持向量机(IHHO-LSSVM)的滚动轴承剩余寿命预测模型.首先,使用集合经验模态分解方法对原信号进行分解,根据相关系数和峭度值选取合适的本征模态函数进行重构;然后,提取时域、频域、小波包能量谱等指标,并用核主成分分析,选取累计贡献率大于 85%的主成分作为轴承退化性能指标;建立最小二乘支持向量机寿命预测模型,针对模型参数,提出一种改进的哈里斯鹰优化算法,并在新算法基础上设计新的能量周期性递减调控机制.采用轴承全寿命实验数据进行验证,结果表明:该方法提取的轴承性能评估指标能够更全面地表征轴承性能退化情况,建立的模型具有良好的预测效果.

关键词: 滚动轴承; 剩余寿命预测; 集合经验模态分解; 哈里斯鹰优化算法; 最小二乘支持向量机; 核主成分分析

中图分类号: TH 133.33; TP 18

文献标志码: A

文章编号: 1000-5013(2022)02-0145-09

IHHO-LSSVM Rolling Bearing Life Prediction Model Treated by EEMD-KPCA

HU Qiguo¹, HE Qi¹, CAO Lijie²

(1. School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074, China;

2. Safety and Environmental Protection Quality Supervision and Inspection Institute,

Chuanqing Drilling Engineering Company, Guanghan 618300, China)

Abstract: In order to improve the prediction accuracy of the remaining life of the rolling bearing, a model based on ensemble empirical mode decomposition-kernel principal component analysis (EEMD-KPCA) and improved Harris hawk optimization-least squares support vector machine (IHHO-LSSVM) was proposed. First, the EEMD method was used to decompose the original signal, and the appropriate eigenmode function was selected for reconstruction according to the correlation coefficient and kurtosis value. Then, the time domain and frequency domain indicators together wavelet packet energy spectrum, etc. were extracted, and using nuclear PCA, the principal component with a cumulative contribution rate greater than 85% was selected as the bearing degradation performance index. The LSSVM life prediction model was established, the parameters of which were optimized by a proposed IHHO algorithm. On the basis of the new algorithm, a new energy cyclical

收稿日期: 2020-12-12

通信作者: 胡启国(1966-),男,教授,博士,主要从事机械可靠性分析及优化、机械系统动力学研究. E-mail: 409500847@qq.com.

基金项目: 国家自然科学基金资助项目(51375519); 重庆市基础科学与前沿技术研究专项资助项目(cstc2015jcyjBX0133)

decrease regulation mechanism was designed. The rolling bearing full life experimental data was used for verification. The results show that the bearing performance evaluation index extracted by the proposed method can more comprehensively characterize the degradation of rolling bearing performance, and the established model has a good prediction effect.

Keywords: rolling bearing; remaining life prediction; ensemble empirical mode decomposition; Harris hawk optimization algorithm; least square support vector machine; kernel principal component analysis

滚动轴承作为机械设备的典型零部件,是决定机械标准件故障预测和健康管理的关键部件之一,剩余寿命对于衡量轴承故障信息有着重要价值^[1].随着机器学习的发展,基于数据驱动的轴承剩余寿命预测逐渐成为国内外研究的主流.但轴承原始信号中不可避免地会有大量噪声,影响了轴承寿命预测的精确度,因此,需要对原始信号进行降噪处理.为了进行退化特征的提取和寿命预测,Yan 等^[2]提出一种使用支持向量机和混合退化跟踪模型,预测轴承的剩余使用寿命;Liu 等^[3]提出一种磷虾群算法,优化基于混合核函数-支持向量回归(HKF-SVR)对轴承性能退化趋势的预测;葛阳等^[4]基于 t -分布领域嵌入算法(t -SNE)和长短期记忆(LSTM)神经网络,对滚动轴承的剩余寿命进行研究;Jiang 等^[5]提出一种基于时间序列的多通道卷积神经网络的轴承剩余使用寿命模型.上述方法为轴承退化特征的提取和寿命预测提供了有效借鉴,但仍有考虑不周的地方,如对原始信号噪声没有进行有效处理,寿命预测只能预测短期的退化趋势且预测结果较为保守.Lu 等^[6]提出最小二乘支持向量机(LSSVM)模型,该模型具有在预测寿命过程中预测精度高和在非线性样本数据中泛化能力好的优点,其预测精度主要受正规化参数 C 和核参数 δ 取值不同的影响.

针对以上问题,本文以提高轴承寿命预测精度为目标,提出一种新的寿命预测方法.首先,用集合经验模态分解(EEMD)方法对原始振动信号进行去噪,再根据相关性系数和峭度值对固有模态函数(IMF)分量信号进行筛选并重构数据;然后,提取重构数据中的时域、频域、小波包能量谱等 22 个特征指标作为特征指标集,并对其进行核主成分分析,选取累计贡献率达到要求的核主成分作为性能退化特征,建立改进的哈里斯鹰优化-最小二乘支持向量机(IHHO-LSSVM)模型.

1 集合经验模态分解原理

Wu 等^[7]针对经验模态分解(EMD)在使用过程中存在噪声或脉冲产生模态混叠的现象,提出一种 EEMD 算法,有效地抑制了 EMD 产生的模态混叠现象.EEMD 具体分解过程如下.

- 1) 在信号中加入一定幅值的白噪声序列,得到新的信号 $x(t)$.
- 2) 新信号 $x(t)$ 经过 EEMD 分解,获得 h 个 IMF 分量 $c_j(t)$ 和 1 个余量 $r(t)$,即

$$x(t) = \sum_{j=1}^k c_j(t) + r(t), \quad j = 1, 2, \cdots, h. \tag{1}$$

- 3) 将分解得到的各个 IMF 分量和剩余余量的均值作为最后结果,最大限度地消除上、下包络线拟合误差.每个 IMF 分量具有稳态性能和相互独立的特点.分解后的 IMF 表示为

$$c_j(t) = \sum_{i=1}^N \frac{c_{i,j}(t)}{N}. \tag{2}$$

2 轴承寿命预测模型的建立

2.1 最小二乘支持向量机预测模型

最小二乘支持向量机由改进支持向量机(SVM)演化而来,其原理是用等式约束替换 SVM 中的不等式约束,将不等式约束的二次规划问题转化成线性矩阵求解问题,与标准的 SVM 相比,LSSVM 的求解速度更快,精度更高.LSSVM 的函数估计问题为

$$\min J(\boldsymbol{\omega}, \boldsymbol{e}) = \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2, \tag{3}$$

$$\text{s. t. } y_i - \boldsymbol{\omega} \boldsymbol{\Phi}(x_j) - \boldsymbol{b} = 0. \tag{4}$$

式(3), (4)中: ω 为权向量; e 为单位矩阵; e_i 为松弛变量, 表示第 i 个数据的预测输出和实际输出的误差值; γ 为惩罚参数; $\Phi = [\varphi(x_1) + \varphi(x_2), \dots, \varphi(x_n)]^T$; b 为偏差向量.

式(3)和式(4)对应的拉格朗日函数为

$$L(\omega, b, e, \alpha) = J(\omega, e) - \sum_{i=1}^l \alpha_i [\omega^T \Phi(x_j) + b + e_i - y_i]. \quad (5)$$

式(5)中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$; α_i 为 Lagrange 乘子. 依据卡鲁什-库恩-塔克(KKT)条件进行求解, 对式(5)中的 ω, b, e, α_i 求偏导数, 并令其偏导数为零. 消掉变量 ω, e , 最终得到的方程组为

$$\begin{bmatrix} \mathbf{0} & \mathbf{I}^T \\ \mathbf{I} & \Phi \Phi^T \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ y \end{bmatrix}. \quad (6)$$

式(6)中: $\mathbf{I} = [1, 1, \dots, 1]^T$; $y = [y_1, y_2, \dots, y_n]^T$.

根据 Mercer 条件, 选择径向基核函数(RBF)作为核函数, 其公式为

$$K(X_i, X_j) = \exp\left(-\frac{|x - x_i|^2}{2\sigma^2}\right). \quad (7)$$

式(7)中: σ 为核函数宽密度.

最终得到的 LSSVM 预测回归模型为

$$f(x) = \sum_{i=1}^n \alpha_i k(x, x_i) + b. \quad (8)$$

2.2 改进的哈里斯鹰优化(IHHO)算法

哈里斯鹰优化(HHO)算法^[8]是 Heidari 受栗翅鹰捕食猎物过程中的群体合作和追逐方式启发, 提出的一种群智能优化算法, 可根据场景的动态性和猎物的逃跑模式揭示多种追逐模式, 由搜索阶段、转化阶段、开发阶段组成. 但原算法易陷入局部最优值, 因此, 对搜索阶段和能量调控机制进行改进.

改进的搜索阶段中, 哈里斯鹰栖息在 $[lb, ub]$ 的空间某位置观察猎物, 迭代时根据所在位置更新概率 p . 当 $p < 0.5$ 时, 其他个体捕食猎物被认为是模仿哈里斯鹰曲折运动的, 采用 Levy 函数(LF)飞行模拟; 当 $p \geq 0.5$ 时, 哈里斯鹰个体移动在内部是随机的, 因此, 通过哈里斯鹰与其他 3 只个体初始值的平均位置来更新位置^[9], 即

$$X(t+1) = \begin{cases} X_m(t) - LF(D)(X_0(t) - X(t)), & p < 0.5, \\ \frac{|X(t) - X_j(t)| - |X(t) - X_k(t)| - |X(t) - X_l(t)|}{3} + X(t), & p \geq 0.5. \end{cases} \quad (9)$$

式(9)中: $X_j(t), X_k(t), X_l(t)$ 为哈里斯鹰随机初始选择的位置; $X_0(t)$ 为猎物位置; $X(t+1), X(t)$ 分别为第 $t+1, t$ 次迭代时个体的位置; $X_m(t)$ 为第 t 次迭代时 N 只个体的平均位置; D 为问题维度.

HHO 算法根据猎物的逃逸能量 E 在搜索和不同的开发行为之间转换, 但 E 的变换是单周期性递减的, 无法描述多个轮次共同追捕猎物的情况^[10]. 因此, 提出一种调控能量周期性的机制, 即多个轮次数以猎物逃逸能量 E 的递变周期数表示, 实现“全局+局部”的寻优搜索能力. 以余弦函数刻画 E 的周期递变性, 其定义式为

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \cdot \cos\left[\left(2k_p + \frac{1}{2}\right)\pi \frac{t}{T}\right]. \quad (10)$$

式(10)中: E_0 为猎物的初始能量, $E_0 \in [-1, 1]$; T 为最大迭代数; k_p 为猎物能量的周期递减数, $k_p = 0, 1, 2, \dots$. 当 $|E| \geq 1$ 时, HHO 进入全局搜索阶段; 当 $|E| < 1$ 时, HHO 算法进入局部开发过程.

在 HHO 算法中, 通过因子 $\beta \in [0, 1]$ 描述猎物是否成功逃脱, 当 $\beta < 0.5$ 时, 表示猎物逃脱成功, 反之则失效. 在开发阶段的寻优过程中包含了 4 种情形^[11].

1) 软围攻. 当 $\beta \geq 0.5$ 且 $0.5 \leq |E| \leq 1.0$ 时, 猎物的能量 E 充足并逃脱, 但最终被捕获, 位置更新为

$$X(t+1) = \Delta X_0(t) - E |J_p X_0(t) - X_0(t)|. \quad (11)$$

式(11)中: $\Delta X_0(t)$ 为第 t 次迭代时鹰与猎物的位置偏差; J_p 为猎物逃跑时的随机跳跃能力, $J_p = 2(1 - r_5)$, r_5 是 $(0, 1)$ 上的一个随机数.

2) 硬围攻. 当 $\beta \geq 0.5$ 且 $|E| < 0.5$ 时, 猎物因能量 E 较低而被鹰直接捕获, 位置更新为

$$X(t+1) = X_0(t) - |E \Delta X_0(t)|. \quad (12)$$

3) 渐进式快速俯冲围捕. 当 $\beta < 0.5$ 且 $0.5 < |E| < 1.0$ 时, 鹰以最优方向俯冲软围捕猎物, 位置为

$$X(t+1)=\begin{cases} Y=X_0(t)-E|JX_0(t)-X_0(t)|, & f(Y)<f(X(t)), \\ Z=Y+S+LF(D), & f(Z)<f(X(t)). \end{cases} \tag{13}$$

式(13)中: S 是 D 维随机向量.

4) 渐进式快速俯冲硬捕. 当 $\beta < 0.5$ 且 $|E| < 0.5$ 时, 猎物能量较低, 鹰俯冲硬捕猎物, 位置更新为

$$X(t+1)=\begin{cases} Y=X_0(t)-E|JX_0(t)-X_m(t)|, & f(Y)<f(X(t)), \\ Z=Y+S+LF(D), & f(Z)<f(X(t)). \end{cases} \tag{14}$$

2.3 IHHO-LSSVM 模型流程图

选取轴承退化特征作为输入向量, 以预测寿命均方误差(MSE)最小化为 IHHO 寻优目标. 以核参数 δ 和正规化参数 C 为优化参数的 IHHO-LSSVM 模型流程图, 如图 1 所示.




图 1 IHHO-LSSVM 模型流程图

Fig.1 Flow chart of IHHO-LSSVM model

3 基于轴承全寿命预测的验证

3.1 实验装置

采用 Gousseau 等^[12]得到的滚动轴承全寿命周期加速轴承性能退化数据. 轴承实验台, 如图 2 所示. 实验过程中, 每个轴承承受 26 670 N 的径向载荷, 每个轴承的横向和纵向各安装了一个压电式加速度传感器, 采样间隔为 10 min, 共采集 984 个样本, 采样频率为 20 kHz, 共采集 20 152 320 个数据. 轴承运行了一周, 直到轴承退化失效. 原始信号图, 如图 3 所示. 图 3 中: a 为加速度; N 为数据样本数量; f 为频率.




图 2 轴承实验台

Fig.2 Bearing test bench




图 3 原始信号图

Fig.3 Original signal diagram

3.2 基于 EEMD 的轴承信号降噪

采集的原始信号中一般含有噪声, 因此, 需要对原始数据进行降噪处理. 分解得到 21 个 IMF 分量, 其相关系数和峭度值, 如表 1 所示. 各个 IMF 分量, 如图 4 所示.

表 1 各个 IMF 的相关系数和峭度值

Tab.1 Correlation coefficient and kurtosis value of each IMF

IMF 分量	相关系数	峭度值	IMF 分量	相关系数	峭度值	IMF 分量	相关系数	峭度值
IMF1	0.955 4	57.635 2	IMF5	0.241 6	33.835 4	IMF9	0.050 1	38.440 4
IMF2	0.722 3	18.919 9	IMF6	0.171 6	37.046 1	IMF10	0.036 0	22.831 5
IMF3	0.503 1	38.310 2	IMF7	0.106 9	48.550 8	IMF11	0.025 1	16.895 3
IMF4	0.370 9	28.256 0	IMF8	0.074 1	34.877 2	IMF12	0.019 3	15.636 8

由图 4 可知: IMF1~IMF12 的振动冲击信号较多, 而 IMF13~IMF20 缺少故障的退化信息, 因此, 对前 12 个 IMF 分量进行筛选. 分解结果中, IMF 分量容易产生虚假的分量, 故引入相关系数和峭度值

以辨别和剔除虚假分量。根据相关系数和峭度值的计算结果可知: 相关系数越接近 1, 表明该 IMF 与原始信息关联越紧密, 对应的距离越小; 峭度值偏离越大, 说明包含的轴承故障信息越多^[13]。因此, 根据表 1 选取 IMF1, IMF3~IMF9 作为重构信号分量。

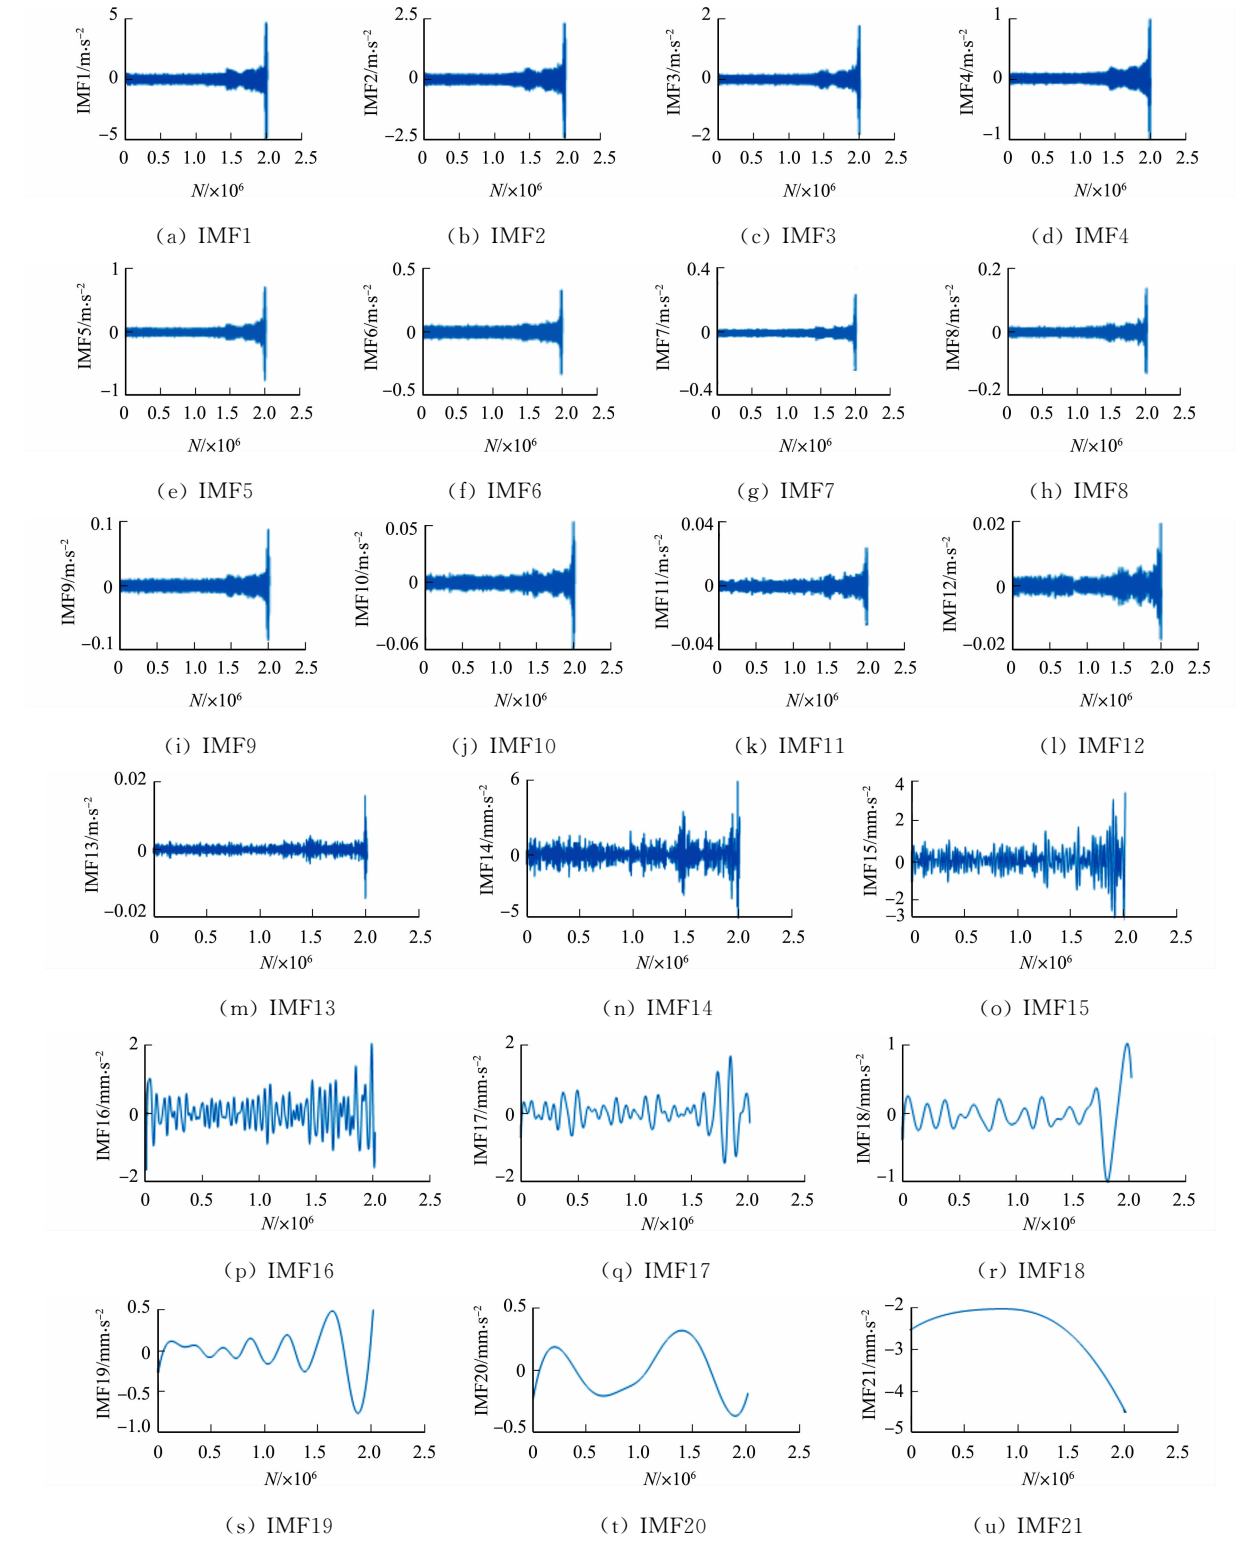


图 4 各个 IMF 分量
Fig. 4 Each IMF component

3.3 验证结果与分析

由于时域、频域各个特征的敏感度皆不相同, 筛选对故障敏感度较高的特征, 剔除退化趋势不明显的特征。在时域退化特征中, 剔除脉冲指标、裕度指标、歪度等几乎无任何变化的退化特征, 筛选出 8 个

时域特征,如图 5 所示. 在 13 个单一频域特征中,选取能够很好地呈现轴承全寿命退化过程的 6 个频域特征指标,如图 6 所示. 图 6 中: P_1 为频域幅值均值; P_2 为频域标准差; P_4 为频域主频带位置; P_5, P_7, P_{13} 为频谱分散或集中程度.

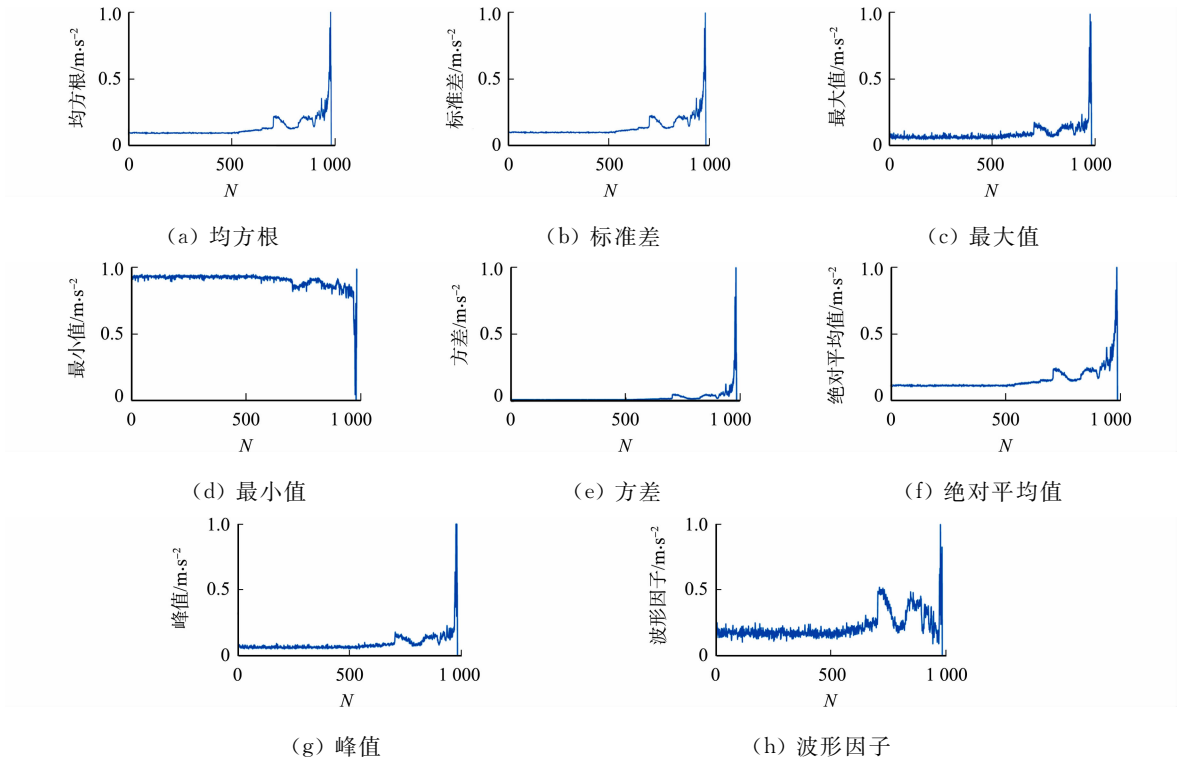


图 5 8 个时域特征

Fig. 5 Eight time domain features

由图 5 可知:8 个时域特征均能反映轴承性能的退化趋势,但其敏感程度各有不同;均方根、标准差和绝对平均值在第 500 个数据点后呈现良好的上升趋势;而峰值、方差、最大值则在第 600 个数据点后逐渐上升. 因此,单一的时域特征可能存在评估能力不足的问题.




图 6 6 个频域特征

Fig. 6 Six frequency domain features

由图 6 可知: P_1 在第 500 个数据点之后出现了小幅度的变化,随着故障程度的加深,其特征指标值也不断变大; $P_2, P_4, P_5, P_7, P_{13}$ 也都反映了轴承退化的趋势.

小波包分解克服了小波分解的不足,提高了信号高频带的频率分辨率和低频带的时间分辨率^[14],其原理是将原始信号分解到不同频带,生成频带能量谱. 选用 db3 小波基函数对重构信号进行 3 层的小波包分解,得到 8 个能够反映轴承全寿命的小波包能量谱($S_{3,1} \sim S_{3,8}$),如图 7 所示. $S_{3,i}$ 中的 3 表示分解

层数, i 表示 8 个频段位置, $i=1,2,\dots,8$.




图 7 8 个小波包能量谱

Fig. 7 Energy spectrum of eight wavelet packets

由图 7 可知:8 个小波包能量谱能有效增强故障和退化特征,完整保留信号频率信息. 在非线性信号中,相比时域、频域的单一特征,小波包能量谱具有分辨率高、精度细化高的优点. 小波包能量谱与时域、频域共同构成多维特征集,更能反映轴承全寿命过程的运行状况. 共选取 22 个退化特征,利用核主成分分析(KPCA)将特征退化指标加权融合. 将 KPCA 第一主成分标准化处理,结果如图 8 所示.

由图 8 可知:KPCA 第一主成分在第 500 个数据点(早期故障)后开始呈现优良的上升趋势. 单一的退化特征则不具备这一优势,利用 KPCA 加权融合提取主成分呈现出的轴承退化性能趋势比单一的特征更全面,该方法使维数得到约简,计算复杂程度减小. 将 KPCA 各主成分的贡献率从大到小依次排列,各主成分的贡献率,如表 2 所示.




图 8 KPCA 第一主成分趋势图

Fig. 8 First principal component trend chart of KPCA

表 2 各主成分的贡献率

Tab. 2 Contribution rate of each principal component

序号	贡献率/%	累计贡献率/%	序号	贡献率/%	累计贡献率/%	序号	贡献率/%	累计贡献率/%
1	59.58	59.58	5	2.81	95.60	9	0.35	98.97
2	20.27	79.85	6	0.97	96.57	10	0.32	99.15
3	6.78	86.64	7	0.70	98.43	11	0.30	99.31
4	6.15	92.79	8	0.49	98.73	12	0.24	99.43

选取累计贡献率达到 85% 的前几个主成分^[15]. 由表 2 可知:前 3 个主成分的贡献率相加得到的累计贡献率为 86.64%,已超过 85%. 故选取轴承退化期的前 3 个主成分和对应的剩余寿命序列组成训练样本,建立 IHHO-LSSVM 寿命预测模型. 将第 500~703 个数据点的退化特征和每一个样本对应的剩余寿命时间序列作为训练样本,等间隔选取第 704~984 个数据点间的 7 个样本作为预测样本,代入剩余寿命预测模型^[16]中,将 LSSVM 的核参数 δ 和正规化参数 C 通过改进的哈里斯鹰算法进行寻优. 对比 HHO 算法与 IHHO 算法的适应度(适应度值选择均方误差)曲线,如图 9 所示. 图 9 中: n 为迭代次数. 由图 9 可知:





图 9 HHO 算法与 IHHO 算法的适应度曲线对比

Fig. 9 Comparison of fitness curves between HHO algorithm and IHHO algorithm


IHHO 算法的收敛精度比 HHO 算法提高了许多。

文中方法是利用 EEMD 去除噪声,分解、重构信号,再用 KPCA 融合的前 3 个主成分作为轴承性能退化指标,最后采用 IHHO-LSSVM 作为寿命预测模型进行模拟.为了评估轴承寿命的预测效果,将 IHHO-LSSVM 模型与采用 EEMD-KPCA 处理的 LSSVM 模型和 IHHO-LSSVM 模型的寿命预测结果进行对比,如图 10 所示.图 10 中: t_r 为剩余寿命.由图 10 可知:3 种模型预测的轴承剩余寿命与真实寿命变化趋势一致。

3 种模型的预测误差对比,如表 3 所示.对比图 10 和表 3



(b) IHHO-LSSVM 模型



(c) EEMD-KPCA 处理的 IHHO-LSSVM 模型

图 10 3 种模型的使用寿命预测结果

Fig. 10 Life prediction results of three models

可知:EEMD-KPCA 处理的 IHHO-LSSVM 模型的均方根误差、平均绝对误差和均方误差均小于 IHHO-LSSVM 模型和 EEMD-KPCA 处理的 LSSVM 模型,说明 EEMD 分解重构具有消除噪声的作用,KPCA 消除了时域、频域等各特征指标间相关性导致的冗余数据;IHHO-LSSVM 模型的预测准确率相比其他支持向量机模型有所提高。

表 3 3 种模型的预测误差对比

Tab. 3 Comparison of prediction errors of three models

预测模型	均方根误差	平均绝对误差	均方误差/ $\text{m} \cdot \text{s}^{-1}$
EEMD-KPCA 处理的 LSSVM 模型	4.326 9	4.001 5	18.721 8
IHHO-LSSVM 模型	2.723 0	3.098 4	13.706 2
EEMD-KPCA 处理的 IHHO-LSSVM 模型	1.118 0	1.449 4	4.223 7

4 结论

- 1) 提出一种新的 EEMD-KPCA 方法,对轴承进行特征处理与提取,该方法既能去噪、又能采用核主成分分析方法剔除无关特征,提高了数据特征的敏感性,为建立寿命预测模型提供了良好的基础。
- 2) 提出一种改变搜索阶段和能量调控机制的改进的哈里斯鹰优化算法.与原算法相比,该方法更容易找到 LSSVM 预测模型的核参数 δ 和正规化参数 C 的最优解。
- 3) 建立一种采用 EEMD-KPCA 处理的 IHHO-LSSVM 滚动轴承寿命预测模型,与 IHHO-LSSVM 预测模型和 EEMD-KPCA 处理的 LSSVM 模型相比,所提模型的预测精度得到了提高,为滚动轴承寿命预测提供了一种新的方法。

参考文献:

[1] WU Bo,LI Wei, QIU Mingquan. Remaining useful life prediction of bearing with vibration signals based on a novel indicator[J]. Shock and Vibration,2017,2017:8927937(1-10). DOI:10.1155/2017/8927937.

- [2] YAN Mingming, WANG Xingang, WANG Bingxiang, *et al.* Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model[J]. *ISA Transactions*, 2020, 98: 471-482. DOI: 10.1016/j.isatra.2019.08.058.
- [3] LIU Fang, LI Liubin, LIU Yongbin, *et al.* HKF-SVR optimized by krill herd algorithm for coaxial bearings performance degradation prediction[J]. *Sensors*, 2020, 20: 660(1-18). DOI: 10.3390/s20030660.
- [4] 葛阳, 郭兰中, 牛曙光, 等. 基于 t-SNE 和 LSTM 的旋转机械剩余寿命预测[J]. *振动与冲击*, 2020, 39(7): 223-231, 273. DOI: 10.13465/j.cnki.jvs.2020.07.031.
- [5] JIANG J R, LEE J E, ZENG Yiming. Time series multiple channel convolutional neural network with attention-based long short-term memory for predicting bearing remaining useful life[J]. *Sensors*, 2019, 20: 166(1-19). DOI: 10.3390/s20010166.
- [6] LU Chao, CHEN Jie, HONG Rongjing, *et al.* Degradation trend estimation of slewing bearing based on LSSVM model[J]. *Mechanical Systems and Signal Processing*, 2016, 76/77: 353-366. DOI: 10.1016/j.ymssp.2016.02.031.
- [7] WU Zhaohua, HUANG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1-41. DOI: 10.1142/S1793536909000047.
- [8] HEIDARI A A, MIRJALILI S, FARIS H, *et al.* Harris hawks optimization: Algorithm and applications[J]. *Future Generation Computer Systems*, 2019, 97: 849-872. DOI: 10.1016/j.future.2019.02.028.
- [9] YOUSRI D, ALLAM D, ETEIBA M B. Optimal photovoltaic array reconfiguration for alleviating the partial shading influence based on a modified harris hawks optimizer[J]. *Energy Conversion and Management*, 2020, 206: 112470. DOI: 10.1016/j.enconman.2020.112470.
- [10] 赵世杰, 高雷阜, 于冬梅, 等. 融合能量周期性递减与牛顿局部增强的改进 HHO 算法[J]. *控制与决策*, 2021, 36(3): 629-636. DOI: 10.13195/j.kzyjc.2019.0810.
- [11] MOSSA M A, KAMEL O M, SULTAN H M, *et al.* Parameter estimation of PEMFC model based on Harris Hawks' optimization and atom search optimization algorithms[J]. *Neural Computing and Applications*, 2021, 33: 5555-5570. DOI: 10.1007/s00521-020-05333-4.
- [12] GOUSSEAU W, ANTONI J, GIRARDIN F, *et al.* Analysis of the rolling element bearing data set of the center for intelligent maintenance systems of the university of Cincinnati[C]// Thirteenth International Conference on Condition Monitoring and Machinery Failure Prevention Technologies. Charenton: HAL, 2016: 1-13.
- [13] 李思琦, 蒋志坚. 基于 EEMD-CNN 的滚动轴承故障诊断方法[J]. *机械强度*, 2020, 42(5): 1033-1038. DOI: 10.16579/j.issn.1001.9669.2020.05.003.
- [14] 张成龙, 郑凯, 刘杰. 基于小波包能量谱和改进 FOA-GRNN 的轴承寿命预测[J]. *组合机床与自动化加工技术*, 2020(7): 73-76, 80. DOI: 10.13462/j.cnki.mmtamt.2020.07.016.
- [15] HU Xiao, XIAO Zhihui, LIU Dong, *et al.* KPCA and AE based local-global feature extraction method for vibration signals of rotating machinery[J]. *Mathematical Problems in Engineering*, 2020, 2020: 5804509(1-17). DOI: 10.1155/2020/5804509.
- [16] 者娜, 杨剑锋, 刘文彬, 等. KPCA 和改进 SVM 在滚动轴承剩余寿命预测中的应用研究[J]. *机械设计与制造*, 2019(11): 1-4, 8. DOI: 10.19356/j.cnki.1001-3997.2019.11.001.

(责任编辑: 黄晓楠 英文审校: 崔长彩)