

11-17-2021

## Fuzzy Information Granulation and Improved RVM for Rolling Bearing Life Prediction

Xiaoman Hu

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;*

Wang Yan

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;*

Zhicheng Ji

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

## Fuzzy Information Granulation and Improved RVM for Rolling Bearing Life Prediction

### Abstract

**Abstract:** Aiming at the low accuracy in life prediction and unpredictable problems of degenerative performance trends and fluctuation ranges, etc. Of the bearing life prediction, an improved complete ensemble empirical mode decomposition with adaptive noise analysis and fuzzy information granulating method of improved relevance vector machine is proposed. *Focusing on bearing data containing a lot of noise, through the improved complete ensemble empirical mode decomposition with adaptive noise analysis in combination with wavelet packet denoising, the principal component analysis is carried out by extracting a variety of characteristics of the signal, the effective information is extracted by granulating the fuzzy information, by entering the improved particle swarm algorithm to optimize the relevance vector machine model of the degradation index range and remaining life is predicted.* The results show that the method can effectively predict the fluctuation range, and the residual life prediction accuracy is improved greatly.

### Keywords

improved complete ensemble empirical mode decomposition with adaptive noise, principal component analysis, bearing remaining life, fuzzy information granulation, particle swarm algorithm, relevance vector machine

### Recommended Citation

Hu Xiaoman, Wang Yan, Ji Zhicheng. Fuzzy Information Granulation and Improved RVM for Rolling Bearing Life Prediction[J]. Journal of System Simulation, 2021, 33(11): 2561-2571.

## 模糊信息粒化与改进 RVM 的滚动轴承寿命预测

胡小曼, 王艳\*, 纪志成

(江南大学 物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

**摘要:** 为解决轴承在寿命预测时精度不高且退化性能趋势及波动范围难以预测等问题, 提出改进自适应完整集成经验模态分解去噪与模糊信息粒化改进相关向量机预测方法。针对轴承数据包含大量噪声问题, 利用改进自适应完整集成经验模态分解结合小波包去噪, 提取信号多种特征进行主成分分析, 将其模糊信息粒化处理以提取有效信息, 输入改进粒子群算法优化相关向量机模型对其退化指标波动范围以及剩余寿命进行预测。结果表明: 该方法能够对其波动范围进行有效预测, 且剩余寿命预测精度大幅提高。

**关键词:** 改进自适应完整集成经验模态分解; 轴承剩余寿命; 主成分分析; 模糊信息粒化; 粒子群算法; 相关向量机

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X (2021) 11-2561-11

DOI: 10.16182/j.issn1004731x.joss.21-FZ0703

## Fuzzy Information Granulation and Improved RVM for Rolling Bearing Life Prediction

Hu Xiaoman, Wang Yan\*, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Wuxi 214122, China)

**Abstract:** Aiming at the low accuracy in life prediction and unpredictable problems of degenerative performance trends and fluctuation ranges, etc. Of the bearing life prediction, an improved complete ensemble empirical mode decomposition with adaptive noise analysis and fuzzy information granulating method of improved relevance vector machine is proposed. *Focusing on bearing data containing a lot of noise, through the improved complete ensemble empirical mode decomposition with adaptive noise analysis in combination with wavelet packet denoising, the principal component analysis is carried out by extracting a variety of characteristics of the signal, the effective information is extracted by granulating the fuzzy information, by entering the improved particle swarm algorithm to optimize the relevance vector machine model of the degradation index range and remaining life is predicted.* The results show that the method can effectively predict the fluctuation range, and the residual life prediction accuracy is improved greatly.

**Keywords:** improved complete ensemble empirical mode decomposition with adaptive noise; principal component analysis; bearing remaining life; fuzzy information granulation; particle swarm algorithm; relevance vector machine

## 引言

作为设备的关键部件, 滚动轴承的工作状况将

直接影响机械安全服役问题, 实时掌握轴承当前的退化趋势及其剩余寿命, 即可避免由于轴承失效等故障引起的意外状况的发生<sup>[1]</sup>。由于工作因素复杂

收稿日期: 2021-04-17 修回日期: 2021-07-17

基金项目: 国家重点研发计划(2018YFB1701903); 国家自然科学基金(61973138)

第一作者: 胡小曼(1997-), 女, 硕士生, 研究方向为智能故障诊断与预测控制。E-mail: 6191913002@stu.jiangnan.edu.cn

通讯作者: 王艳(1978-), 女, 博士, 教授, 研究方向为制造系统性能优化。E-mail: wangyan@jiangnan.edu.cn

多样, 很容易导致轴承性能退化, 因此, 通过建立预测模型来预测其性能退化指标及其寿命, 及时进行早期预警及故障维修, 即可有效防止因轴承故障而导致的经济损失以及人员伤亡<sup>[2]</sup>。

目前, 利用设备状态监测数据进行轴承的退化性能趋势及其寿命预测是本领域重点研究方向之一。该方法主要包括2方面内容: ①对轴承进行退化评估对其退化趋势进行预测; ②通过预测模型对滚动轴承进行寿命预测<sup>[3]</sup>。

由于在实际生产过程中, 提取的轴承振动信号包含大量噪声, 在进行寿命预测时要对轴承振动信号进行去噪处理。目前国内外有多种对振动信号预处理方式, 常见的例如小波变换、变模态分解、傅立叶变换、经验模态分解等。其中经验模态分解(Empirical Mode Decomposition, EMD)解决了小波分析中选择小波基的问题, 然而却存在模态混叠问题, 文献[4]将集成经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)用于提取信息, 该方法可有效解决EMD的缺陷, 但却存在巨大的重构误差。文献[5]对其进行改进提出自适应完整集成经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise Analysis, CEEMDAN), 而ICEEMDAN是对CEEMDAN的进一步改进, 但单一的ICEEMDAN在去噪时易丢失轴承有效信息, 因此本文提出ICEEMDAN与小波包结合的算法对轴承振动信号进行去噪。

退化性能指标的提取对于寿命预测具有重要意义, 文献[6]提出提取轴承时域指标作为退化性能指标进行预测, 然而单一的指标通常难以全面反映轴承性能退化趋势, 因此本文同时提取其时域、频域、时频域3方面特征通过主元分析进行融合。在寿命预测方面, 文献[7]提出基于支持向量机(Support Vector Machines, SVM)的轴承性能趋势退化预测方法, 但是该方法计算量大, 需要参数多, 且文献没有将其用于轴承剩余寿命预测。

目前, 对于轴承退化性能趋势进行预测通常只能得出一个预测值, 而在实际工作中, 还希望得到

其退化指标的波动范围, 因此将主成分融合后的主元进行模糊信息粒化, 以得到窗口的有效信息, 最后采用改进粒子群算法输出优化相关向量机(Relevance Vector Machine, RVM)核宽度的最佳参数, 将提取到的信息输入给优化后的RVM进行预测, 从而对轴承退化性能指标和波动范围以及剩余寿命进行有效预测。

## 1 振动信号去噪与性能退化指标提取

### 1.1 ICEEMDAN 与小波包去噪

#### 1.1.1 ICEEMDAN

CEEMDAN在信号分解时, 添加高斯白噪声序列, 在分解过程中, 该方法利用上一个模态分量(Intrinsic Mode Functions, IMF)分解后的残差来计算下一个模态<sup>[8]</sup>。而ICEEMDAN是添加一种非高斯白噪声的特殊噪声, 该方法不仅降低了IMF分量残余噪声, 并且模态混叠现象也得到了解决<sup>[9]</sup>。

定义 $M(\cdot)$ 为分解信号局部均值, 则均值 $E_1(x) = x - M(x)$ ,  $E_k(\cdot)$ 为经验模态分解产生的第 $k$ 个IMF分量:

$$(1) \text{ 设原始信号为 } x, \text{ 添加 } E_1^{w(i)} \text{ 给原始信号} \\ x^i = x + \beta_0 E_1^{w(i)} \quad (1)$$

式中:  $w(i)$ 为添加的第 $i$ 个白噪声;  $\beta_0$ 为白噪声的标准差。

(2) 通过计算 $x^i$ 的 $M(\cdot)$ , 并将其求和取均值, 将其作为第一个残差分量 $r_1$

$$r_1 = \frac{1}{n} \sum_{i=1}^n M(x^i) \quad (2)$$

则第一个IMF分量 $C_1 = x - r_1$ 。

(3) 计算第二个IMF分量 $C_2 = r_1 - r_2$ , 其中

$$r_2 = \frac{1}{n} \sum_{i=1}^n M(r_1 + \beta_1 E_2^{w(i)}) \quad (3)$$

(4) 计算第 $m$ 个IMF值与残差

$$C_m = r_{k-1} - r_k \\ r_m = \frac{1}{n} \sum_{i=1}^n M(r_{m-1} + \beta_{m-1} E_m^{w(i)}) \quad (4)$$

### 1.1.2 自相关函数

由于信号经 ICEEMDAN 分解后得到不同个数的 IMF 分量, 不同的 IMF 分量对应不同的信号(低阶对应高频, 高阶对应低频)因此如何界定噪声分界点  $k$  成为一个难点。目前主要的分析方法分为 2 种: 主观判定法与互相关系数法<sup>[10]</sup>。前者为人为判断, 主观性高, 后者易将低频主导信号去除。而本文提出的自相关函数, 当自相关程度最大时对应刻度为 0, 相关程度由 0 点开始向两侧递减, 其递减的程度及速率与其含有的噪声成正比, 对于含有较多噪声的有效信号则迅速递减, 而对于含有较少噪声的有效信号, 则在其他时刻并不会快速衰减至零刻度<sup>[11]</sup>, 可以在不同时刻反映信号的相关程度。因此, 本文通过自相关分析与自相关方差确定分界点  $k$ 。

自相关函数定义:

$$R_x(t_1, t_2) = E(x(t_1), x(t_2)) \quad (5)$$

式中:  $x(t)$  为随机信号。

### 1.1.3 小波包阈值去噪

小波包是小波变换的进一步优化, 与其相比, 小波包可以通过小波变换对于其分解得到的小波系数进一步分解, 根据其特征, 自适应的选择频带<sup>[12]</sup>。具体分解步骤如下:

step 1: 设本文中带有噪声的信号为  $s$ , 原始信号为  $x$ , 加入噪声  $n$ :

$$s = x + n \quad (6)$$

step 2: 利用小波函数  $ddencmp$  得出所需参数, 并设置小波基与分解层数;

step 3: 使用  $wpdencmp$  函数降噪, 将噪声信号分解为一系列小波包系数;

step 4: 使用软阈值处理降噪;

step 5: 重构信号, 得到去噪信号。

### 1.1.4 基于 ICEEMDAN 与小波包阈值去噪流程

去噪流程如图 1 所示。

去噪流程:

step 1: 利用 ICEEMDAN 对原始振动信号分解, 得到一连串 IMF 分量;

step 2: 利用自相关函数法确定去噪分界点  $k$ ;

step 3: 将前  $k$  个 IMF 分量利用小波包软阈值去噪;

step 4: 将未处理的分量与去噪后的 IMF 分量重构。

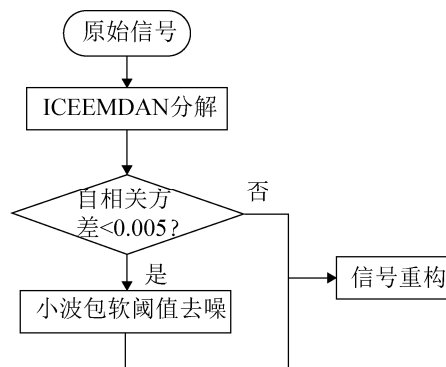


图 1 ICEEMDAN 与小波包软阈值去噪流程  
Fig. 1 ICEEMDAN and wavelet packet soft threshold denoising process

## 1.2 性能退化指标提取

### 1.2.1 时域指标

时域指标跟随时间的变化而变化, 可根据时域特征参数的变化辨别设备是否发生故障。常用的时域指标主要有方均根值、波形、均值、脉冲等。

### 1.2.2 频域指标

频域指标可以更加直观地对轴承信号进行分析, 主要反映其振动能量的大小以及频谱的分布等情况<sup>[12]</sup>, 常用的频域指标主要有频率中心、均值中心等。

### 1.2.3 时频域指标

单一的时域、频域指标不能完整反映非线性信号的退化趋势, 因此需采用 ICEEMDAN 分解, 提取 IMF 能量作为轴承退化性能的时频域指标。

## 2 主成分分析融合多特征指标降维与模糊信息粒化

### 2.1 主成分分析加权降融合

主成分分析是一种特征降维的方法。假设

$x_i (i=1,2,\dots,m)$  为一组相关变量, 表示去噪后的轴承样本, 利用主成分分析(Principal Components Analysis, PCA)将其转换为一组不相关的变量  $y_j (j=1,2,\dots,k)$ , 即

$$\begin{cases} y_1 = \alpha_{11}x_1 + \alpha_{12}x_2 + \dots + \alpha_{1m}x_m \\ y_2 = \alpha_{21}x_1 + \alpha_{22}x_2 + \dots + \alpha_{2m}x_m \\ \vdots \\ y_k = \alpha_{k1}x_1 + \alpha_{k2}x_2 + \dots + \alpha_{km}x_m \end{cases} \quad (7)$$

式中:  $\alpha_i = (\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{im})^T$ ,  $i = (1, 2, \dots, k)$  表示协方差矩阵中按照降序排序中第  $i$  个特征值  $\lambda_i$  对应的特征向量, 其中:

$$\begin{cases} \alpha_i^T \alpha_j = 1, i = j \\ \alpha_i^T \alpha_j = 0, i \neq j \end{cases} \quad (8)$$

协方差矩阵:

$$C = \begin{bmatrix} \text{cov}(x_1, x_1) & \text{cov}(x_1, x_2) & \dots & \text{cov}(x_1, x_m) \\ \text{cov}(x_2, x_1) & \text{cov}(x_2, x_2) & \dots & \text{cov}(x_2, x_m) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(x_m, x_1) & \text{cov}(x_m, x_2) & \dots & \text{cov}(x_m, x_m) \end{bmatrix} = \frac{1}{m} \mathbf{A} \mathbf{A}^T \quad (9)$$

其中

$$\text{cov}(x_i, x_j) = E[(x_i - Ex_i)(x_j - Ex_j)^T] \quad (10)$$

特征方程:  $C\alpha_i = \lambda_i \alpha_i$

Hankel 矩阵:

$$A = \begin{bmatrix} a(1) & a(2) & \dots & a(n) \\ a(2) & a(3) & \dots & a(n+1) \\ \vdots & \vdots & \ddots & \vdots \\ a(m) & a(m+1) & \dots & a(n+m-1) \end{bmatrix} \quad (11)$$

式中:  $a = [a(1), a(2), \dots, a(n)]$ , 表示一维零均值离散信号。

## 2.2 模糊信息粒化

信息粒化(Information Granulation, IG)是将一个整体作为部分来研究, 信息粒就是将一些相似或难以区分的数据信息进行整体处理<sup>[13]</sup>, 以掌握其基本信息。本文采用模糊集理论模型, 该过程主要包含 2 个步骤: 窗口划分与信息模糊化。

窗口划分: 将滚动轴承整个寿命按照时间划分为很多子序列, 将每一个时段作为一个时间窗口, 进行后续操作计算。

模糊信息化: 将每一个信息粒模糊化, 提取原始信息中的有效信息。模糊化的主要任务就是建立一个模糊粒子  $P$ , 其中模糊粒子是根据能够描述原始信息的模糊集  $G$  而建立, 其本质就是确定  $G$  的隶属函数  $A$ , 其中  $A = \mu_G$ 。

为更好地评估滚动轴承退化性能趋势及其波动范围, 本文采用三角形模糊信息粒对其进行处理, 隶属度函数

$$A(x, a, m, b) = \begin{cases} 0, x < a \\ (x-a)(m-a), a \leq x \leq m \\ (b-x)(b-m), m < x \leq b \\ 0, x > b \end{cases} \quad (12)$$

## 3 相关向量机参数优化

### 3.1 相关向量机

RVM 是与 SVM 类似的一种新的监督学习方法。RVM 在选择核函数时不需要考虑 Mercer 条件, 并且非常适用于处理非线性及小样本问题<sup>[14]</sup>, 且其泛化能力强, 精度高。

设训练集  $D = \{(x_i, y_i)\}^n$ , 则 RVM 目标输出为:

$$y(x, w) = \sum_{i=1}^n w_i k(x, x_i) + w_0 \quad (13)$$

式中:  $n$  为样本总数;  $k(x, x_i)$  为核函数,  $w = (w_1, w_2, \dots, w_M)$

假定  $t_n$  服从高斯分布:

$$P(t_n | x) = N(t_n | y(x_n), \sigma^2) \quad (14)$$

则训练集样本的概率为:

$$P(t_n | w, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{\|t - \phi w\|^2}{2\sigma^2}\right) \quad (15)$$

式中:  $t = (t_1, t_2, \dots, t_n)$ ;  $\phi = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)]$

采用径向基核函数:

$$k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (16)$$

## 3.2 改进粒子群算法

### 3.2.1 标准粒子群算法

粒子群算法由于所需参数少、优化效率高等优点被广泛使用<sup>[15]</sup>, 假设种群维度为  $D$ ,  $N$  记为粒子数目, 位置记为  $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,n})$ , 速度记为  $v_i = (v_{i,1}, v_{i,2}, \dots, v_{i,n})$ , 则种群更新:

$$v_{i,d}^{t+1} = w_p^t v_{i,d}^t + c_1^t \text{rand}_1(p_{\text{best}_{i,d}}^t - x_{i,d}^t) + c_2^t \text{rand}_2(g_{\text{best}_{i,d}}^t - x_{i,d}^t) \quad (17)$$

$$x_{i,d}^{t+1} = x_{i,d}^t + v_{i,d}^{t+1} \quad (18)$$

式中:  $p_{\text{best}_{i,d}}^t$ ,  $g_{\text{best}_{i,d}}^t$  分别为第  $i$  个粒子在  $t$  时刻的个体最优与全局最优位置;  $c_1^t$  为自身学习因子;  $c_2^t$  为社会学习因子;  $w_p^t$  为惯性权重。

### 3.2.2 Tent 混沌映射

混沌理论是集合非线性、随机性、初值敏感性、便利性等特点的一种复杂的非线性动态行为<sup>[16]</sup>。混沌优化的使用则可以有效避免 PSO 算法陷入局部最优, 追求算法卓越的寻优效率。

$$z_{i+1} = \begin{cases} 2z_i, & 0 \leq z \leq 0.5 \\ 2(1-z_i), & 0.5 \leq z \leq 1 \end{cases} \quad (19)$$

经贝努力移位变换后如下:

$$z_{i+1} = (2z_i) \bmod 1 \quad (20)$$

引入随机变量  $\text{rand}(0,1) \times \frac{1}{NT}$ , 解决映射中不稳定周期点问题:

$$z_{i+1} = \begin{cases} 2z_i + \text{rand}(0,1) \times \frac{1}{NT}, & 0 \leq z \leq 0.5 \\ 2(1-z_i) + \text{rand}(0,1) \times \frac{1}{NT}, & 0.5 \leq z \leq 1 \end{cases} \quad (21)$$

移位变换后:

$$z_{i+1} = (2z_i) + \bmod 1 + \text{rand}(0,1) \times \frac{1}{NT} \quad (22)$$

式中:  $NT$  为粒个数。

具体步骤如下:

step 1:  $i = 0$ , 在  $(0,1)$  内随机产生初始值;

step 2: 根据式(22)进行迭代,  $i = i + 1$ ;

step 3: 当达到最大迭代次数, 则停止运行, 保留混沌序列。

### 3.2.3 自适应混沌搜索

利用自适应动态调整混沌搜索策略, 更新粒子位置, 产生适应度较好的新值, 利用种群目前最优值产生 Tent 序列, 具体步骤如下:

step 1: 利用式(22)产生混沌变量  $z_d$ ;

step 2: 将  $z_d$  还原到待求问题解空间。

$$X_{d,\text{new}} = \min X_{d,\text{new}} + (\max X_{d,\text{new}} - \min X_{d,\text{new}}) \cdot z_d \quad (23)$$

式中:  $\min_d$ ,  $\max_d$  为  $X_{d,\text{new}}$  的最小值与最大值;

step 3: 对个体进行混沌扰动产生新个体  $X'_{\text{new}}$ :

$$X'_{\text{new}} = (x' + X_{\text{new}}) / 2 \quad (24)$$

式中:  $X_{\text{new}}$  为扰动量;  $x'$  为需要进行混沌扰动的个体。

### 3.2.4 高斯变异

高斯变异具体方法是用符合  $N(\mu, \sigma^2)$  的随机数来代替原始数值, 以提高跳出局部最优的能力。

$$x_{\text{new}} = x + xN(0,1) \quad (25)$$

式中:  $x$  为原有数值;  $x_{\text{new}}$  为新生数值。

## 3.3 优化相关向量机步骤

step 1: 初始化种群相关参数:  $D$ ,  $N$ ,  $x_i$ ,  $v_i$ , 设粒子初始值为当前算法的最优值, 计算适应度, 获得当前种群最优;

step 2: 根据式(21)产生混沌序列, 利用式(23)将其载波到待求解问题的取值范围内, 计算每个粒子平均适应度  $\bar{f}$ , 选取最优适应度值与其对应的位置对种群进行更新;

step 3: 计算种群平均适应度  $\bar{f}$ , 当符合条件  $f_i \leq \bar{f}$ , 对种群进行高斯变异, 若变异后个体更优, 则代替原个体, 否则保持原来粒子不变; 当  $f_i > \bar{f}$ , 对个体进行混沌扰动, 同理, 选择最优个体;

step 4: 根据式(17), (18)对种群进行更新, 重新计算最优粒子适应度与位置;

step 5: 当达到终止条件时, 输出优化 RVM 核宽度的最佳参数, 构建预测模型。

## 4 轴承寿命预测步骤

基于模糊信息粒化与改进相关向量机轴承剩

余寿命预测步骤如下:

step 1: 轴承振动信号去噪。利用 ICEEMDAN 对振动信号进行分解, 利用自相关函数法确定去噪分界点  $k$ , 由于前  $k$  个 IMF 分量包含大量噪声, 因此将前  $k$  个 IMF 分量利用小波包软阈值去噪;

step 2: 提取时域、频域、时频域退化性能指标, 利用 PCA 加权融合, 去除高维冗余变量, 构造去相关的退化性能指标;

step 3: 模糊信息粒化处理。将降维后的指标利用模糊信息粒化进行处理, 并对其进行归一化;

step 4: RVM 参数优化。采用改进粒子群算法输出优化相关向量机的最佳参数, 构建预测模型;

step 5: 将粒化后的数据输入优化后的预测模型, 对其退化性能指标及其波动范围进行预测, 最后对其失效前开始退化后的剩余寿命进行预测, 以绝对平均误差、均方根误差、平均相对误差及决定系数为指标进行性能评估分析。

滚动轴承剩余使用寿命预测步骤如图 2 所示。

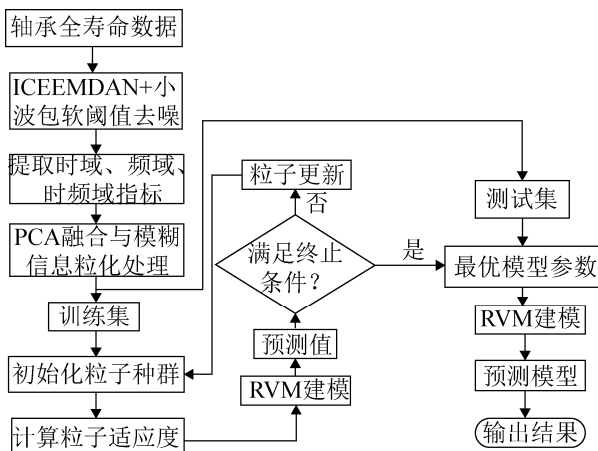


图 2 滚动轴承寿命预测流程

Fig. 2 Rolling bearing life prediction process

## 5 实验结果与分析

实验数据来自美国辛辛那提大学。实验台具体装置如图 3 所示。本文采用的数据信号采样频率为 20 kHz, 样本长度为 20 480, 共 984 个样本<sup>[17]</sup>, 数据采集的时间间隔为 10 min。本文采用实验二轴承 1 因外圈发生故障而结束采集的轴承全寿命数据。




图 3 轴承实验装置

Fig. 3 Bearing test apparatus

### 5.1 基于 ICEEMDAN 与小波包去噪

将轴承全寿命每个样本隔 100 点取样, 利用 ICEEMDAN 进行分解, 轴承原始信号如图 4 所示。




图 4 轴承原始信号

Fig. 4 Bearing original signal

分解后 IMF 分量只展示前 12 个, 如图 5 所示。计算各 IMF 分量的自相关函数, 计算结果如图 6 所示。

各 IMF 自相关方差如图 7 所示。

由图 6~7 可以看出, 前 8 阶 IMF 分量为噪声主导模式分量, 且其自相关方差均小于 0.005, 后各阶 IMF 分量为有效信号模式分量, 因此选择去噪分离点  $k=8$ , 前 8 阶 IMF 分量使用小波包软阈值去噪, 后各阶 IMF 分量保持不变, 将用上述方法进行去噪后的分量与未处理的分量重构, 并将其与原始信号进行对比, 如图 8 所示。

由图 8 可以看出, 经本文方法处理去噪后, 波形没有发生明显变化, 保留了大部分有效信息, 且削弱了噪声的影响, 可证明本文所提去噪方法的有效性。



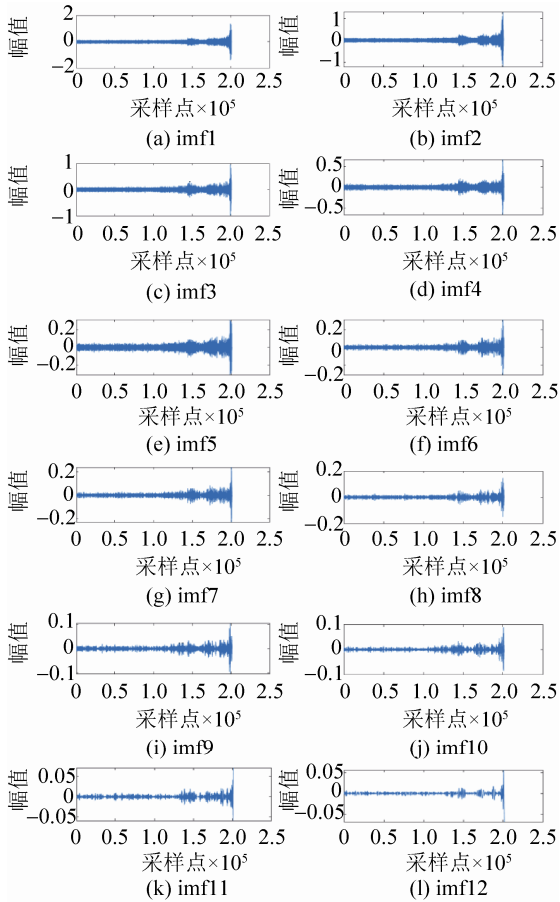


图 5 IMF1-12  
Fig. 5 IMF 1-12

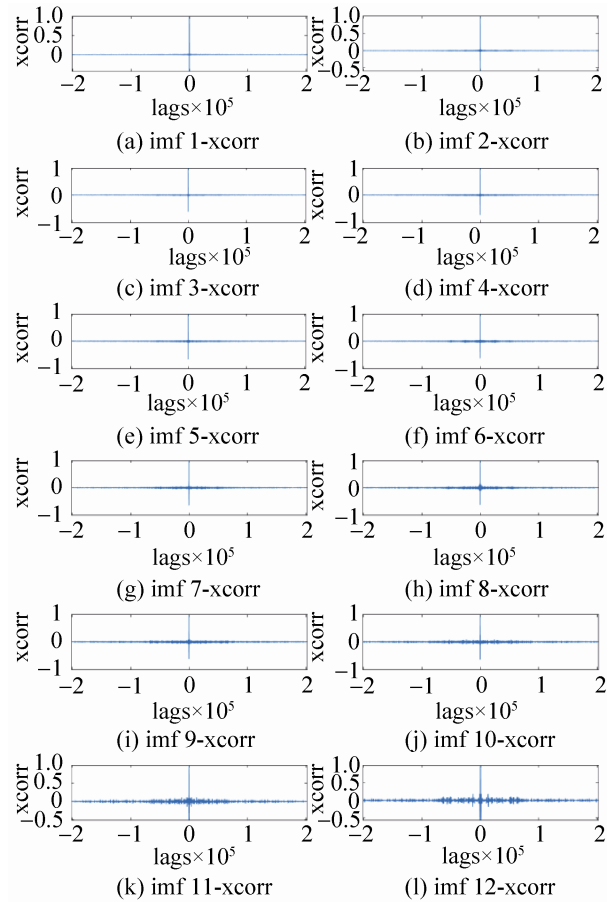


图 6 IMF 自相关函数  
Fig. 6 Cross-correlation function for IMF




图 7 IMF 自相关方差  
Fig. 7 Cross-correlation variance for IMF




图 8 去噪结果对比图  
Fig. 8 Comparison diagram of denoising results

## 5.2 特征提取

由于单一时域、频域信号难以反映轴承性能退化趋势, 导致预测效果不理想, 因此, 本文将轴承原始信号降噪后, 提取 16 个时域特征、12 个频域特征指标, 以及由 ICEEMDAN 分解后的时频域能

量特征如图 9~10 所示。

由图 9~10 可以看出, 时域无量纲特征中偏斜度、峭度对轴承退化早期故障不敏感, 不能有效反映退化起始阶段, 图 10 中前 3 个指标过于嘈杂, 无法表示有用信息, 故将前 3 个指标去掉, 保留时域无量纲特征 8 个与时域无量纲特征 3 个。

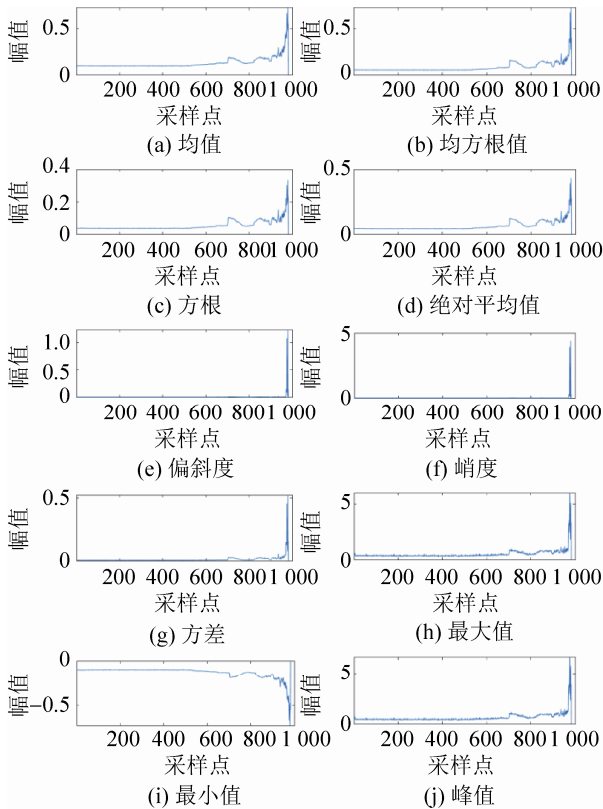


图 9 时域有量纲特征

Fig. 9 Dimensional characteristics of time domain




图 10 时域无量纲特征

Fig. 10 Dimensionless characteristics of time domain

由图 11 可知, 标准差频率、频率特征 3、频率特征 8 对于轴承早期退化故障不敏感, 因此将其去除, 剩余 9 个频域特征指标。

由图 12 可得, 只有前 3 个 IMF 能量对轴承早期故障较为敏感, 故将前 3 个能量特征保留, 将后几个 IMF 能量特征剔除。

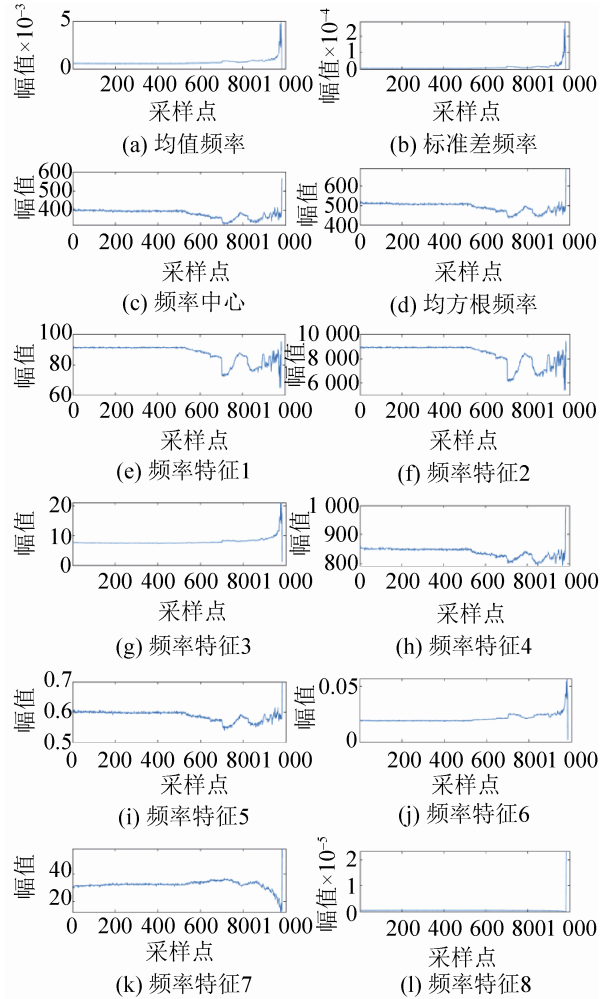


图 11 频域特征

Fig. 11 Frequency domain characteristics




图 12 时频域特征

Fig. 12 Time-frequency domain features

### 5.3 PCA 降维与模糊信息粒化

将保留的 11 个时域特征、9 个频域特征、3 个时频域特征利用 PCA 进行融合降维处理, 各主成分贡献度如表 1 所示, 提取前 4 个主成分加权融合后进行模糊信息粒化。本文以 3 个点为一个窗口进行信息粒化, 粒化后轴承全寿命变化如图 13 所示, 其中 *low* 表示最小值, *R* 表示平均值, *up* 表示最大值。

表 1 部分主成分贡献度  
Tab. 1 Partial principal component contribution

序号	贡献度/%	累积贡献度/%
1	85	85
2	7	92
3	5	97
4	2	99





图 13 模糊信息粒化  
Fig. 13 Fuzzy information granulation

由图 13 可以看出, 在 170 窗口附近处其粒化值随轴承故障发展而上升, 而单一时域或频域特征在 234 窗口处才对中轴承早期退化特征有所反应, 证明本文所题方法的有效性。


### 5.4 轴承退化性能趋势预测

用改进粒子群算法优化 RVM 的核宽度, 设置种群个数为 30, 最大迭代次数为 100, 将优化后的核宽度构建 RVM 模型进行训练, 并对模糊信息粒化后的最小值、平均值及最大值归一化处理作为 RVM 输入, 对轴承退化趋势进行预测。选择整体中 350 窗口作为样本以供计算, 前 280 个粒化窗口


作为本文计算的训练集, 后 70 个窗口作为本文模拟的测试集轴承退化性能趋势预测如图 14 所示。



(a) *low* 预测输出



(b) *R* 预测输出



(c) *up* 预测输出

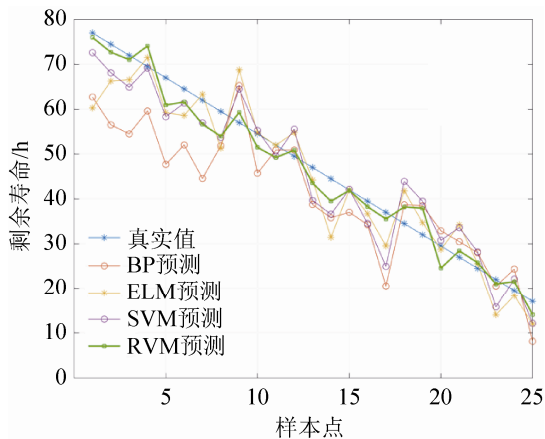
图 14 参数预测值  
Fig. 14 Parameter predicted value

由图 14 可以看出, 基于模糊信息粒化后各个窗口 *low*, *R*, *up* 能够较好地跟踪轴承退化性能趋

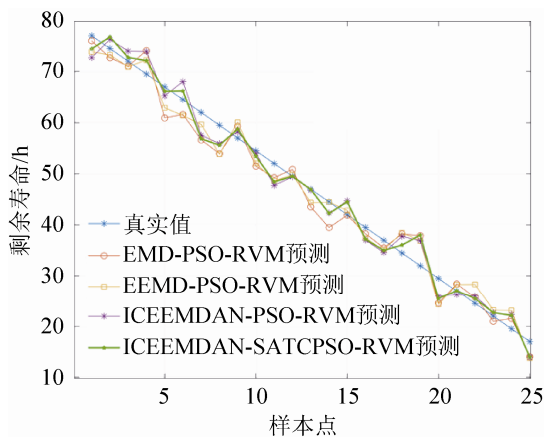
势,在轴承失效以前预测效果较为良好,且能充分表征轴承退化性能趋势的波动范围,及时发现早期性能退化时刻并对设备进行维护。

### 5.5 轴承剩余寿命趋势预测

将降维后累计贡献率超过 99%主成分进行模糊信息粒化后进行预测,从第 170 个窗口开始,每隔 4 个点取一处组成测试样本,取 25 个样本作为测试集。为证明本文所提方法的优越性,分别利用 Bp,ELM 神经网络、SVM,EMD-PSO-RVM,EEMD-PSO-RVM,ICEEMDAN-PSO-RVM,ICEEMDAN-SATCPSO-RVM 对模糊信息粒化后的数据进行预测,并计算以上各模型的 MAE, MPE, RMSE 以及决定系数  $R^2$ ,预测结果及误差对比结果如图 15,表 2~3 所示。



(a) 不同方法预测对比



(b) 优化后预测对比

图 15 预测对比

Fig. 15 Predict contrast

表 2 预测误差对比

Tab. 2 Comparison of prediction error		/%		
模型	MAE	MPE	RMSE	$R^2$
BP	8.641 5	0.112 2	10.275 2	0.789 5
ELM	5.298 6	0.107 7	6.814 0	0.872 8
SVM	5.287 0	0.068 7	6.004 9	0.896 0
RVM	3.366 7	0.059 4	4.006 8	0.967 0

表 3 优化后预测误差对比

Tab. 3 Comparison of prediction error		/%		
模型	MAE	MPE	RMSE	$R^2$
EMD-PSO-RVM	3.366 7	0.059 4	4.006 8	0.967 0
EEMD-PSO-RVM	2.692 5	0.048 9	3.061 7	0.973 5
ICEEMDAN-PSO-RVM	2.496 8	0.032 4	2.866 2	0.975 1
ICEEMDAN-SATCPSO-RVM	2.173 5	0.028 2	2.642 7	0.978 9

由图 15(b)与表 3 可以看出,3 种优化算法效果均较为良好,相比于 EMD-PSO-RVM, EEMD-PSO-RVM, ICEEMDAN-PSO-RVM, 本文提出的 ICEEMDAN-SATCPSO-RVM 模型其绝对平均误差相比于 ICEEMDAN-PSO-RVM 降低 0.323 3, 平均相对误差降低 0.004 2, 均方根误差降低 0.223 5, 且其决定系数增加 0.003 8, 预测误差最小, 决定系数最大。

## 6 结论

针对轴承性能退化趋势、波动范围以及剩余寿命难以预测等问题。本文提出改进自适应完整集成经验模态分解去噪融合主成分分析与模糊信息粒化的改进相关向量机预测方法。

由于轴承振动信号包含大量噪声,因此本文提出基于 ICEEMDAN 与小波包软阈值结合去除噪声的方法,结合自相关函数与方差确定去噪分界点  $k$ ,结果表明,本文提出改进自适应完整集成经验模态分解去噪融合主成分分析与模糊信息粒化的改进相关向量机预测方法去噪效果良好。针对单一时域、频域不能完全表征轴承性能,本文将轴承的时域、频域、时频域 3 部分特征利用 PCA 融合后进行预测。且由于轴承性能退化波动范围难以预测,本文将降维后主成分融合进行模糊信息粒化处理后再进行预测,结果表明预测效果良好。最后,本文构造了 ICEEMDAN-SATCPSO-RVM 预测模

型, 仿真结果表明, 与 ELM, BP, SVM, EMD-PSO-RVM, EEMD-PSO-RVM, ICEEMDAN-PSO-RVM 相比, 本文提出的优化方法不仅可以预测轴承的性能退化波动范围及其趋势, 且寿命的预测结果更加可靠。

### 参考文献:

- [1] Wang H, Ni G X, Chen J H, et al. Research on Rolling Bearing State Health Monitoring and Life Prediction based on PCA and Internet of Things with Multi-sensor[J]. *Measurement (S0263-2241)*, 2020, 157(107657): 1-12.
- [2] 康守强, 周月, 王玉静, 等. 基于改进 SAE 和双向 LSTM 的滚动轴承 RUL 预测方法[J/OL]. *自动化学报*, 2020. DOI:10.16383/j.aas.c190796.  
Kang Shouqiang, Zhou Yue, Wang Yujing, et al. RUL Prediction Method of a Rolling Bearing based on Improved SAE and Bi-LSTM[J/OL]. *Acta Automatica Sinica*, 2020. DOI:10.16383/j.aas.c190796.
- [3] Meng Z, Li J, Yin N, et al. Remaining useful Life Prediction of Rolling Bearing Using Fractal Theory [J]. *Measurement (S0263-2241)*, 2020, 156(1075721): 1-10.
- [4] Fang Y M, Guan B, Wu S J, et al. Optimal Forecast Combination Based on Ensemble Empirical Mode Decomposition for Agricultural Commodity Futures Prices[J]. *Journal of Forecasting (S0277-6693)*, 2020, 39(6): 877-886.
- [5] Guo Y N, Cao X Q, Liu B N, et al. Chaotic Time Series Prediction Using LSTM with CEEMDAN [J]. *Journal of Physics: Conference Series (S1742-6588)*, 2020, 1617(1): 012094-012100.
- [6] 肖婷, 汤宝平, 秦毅, 等. 基于流形学习和最小二乘支持向量机的滚动轴承退化趋势预测[J]. *振动与冲击*, 2015, 34(9): 149-153.  
Xiao Ting, Tang Baoping, Qin Yi, et al. Degradation Trend Prediction of Rolling Bearing based on Manifold Learning and Least Squares Support Vector Machine[J]. *Journal of Vibration and Shock*, 2015, 34(9): 149-153.
- [7] 徐继亚, 王艳, 严大虎, 等. 融合 KPCA 与信息粒化的滚动轴承性能退化 SVM 预测[J]. *系统仿真学报*, 2018, 30(6): 2345-2354.  
Xu Jiya, Wang Yan, Yan Dahu, et al. SVM Prediction of Performance Degradation of Rolling Bearings with Fusion of KPCA and Information Granulation[J]. *Journal of System Simulation*, 2018, 30(6): 2345-2354.
- [8] Wu J, Miu F, Li T Y. Daily Crude Oil Price Forecasting Based on Improved CEEMDAN, SCA, and RVFL: A Case Study in WTI Oil Market[J]. *Energies (S1996-1073)*, 2020, 13(7): 1852-1872.
- [9] Li T Y, Qian Z J, He T, et al. Short-Term Load Forecasting with Improved CEEMDAN and GWO-Based Multiple Kernel ELM [J]. *Complexity (S1076-2787)*, 2020:1209547.
- [10] 董利超, 郭兴明, 郑伊能. 基于 CEEMD 的心音信号小波包去噪算法研究[J]. *振动与冲击*, 2019, 38(9): 192-198, 222.  
Dong Lichao, Guo Xingming, Zheng Yineng. Wavelet Packet De-noising Algorithm for Heart Sound Signals based on CEEMD[J]. *Journal of Vibration and Shock*, 2019, 38(9): 192-198, 222.
- [11] 刘晓光, 郝沙沙, 王光磊, 等. 基于自相关特性的经验模态分解微机械陀螺去噪方法[J]. *中国惯性技术学报*, 2016, 24(4): 537-541.  
Liu Xiaoguang, Hao Shasha, Wang Guanglei, et al. Micro Mechanical Gyro Denoising Method based on EMD Autocorrelation[J]. *Journal of Chinese Inertial Technology*, 2016, 24(4): 537-541.
- [12] Su Y T, Lin S J. On Initial Fault Detection of a Tapered Roller Bearing: Frequency Domain Analysis[J]. *Journal of Sound and Vibration (S0022-460X)*, 1992, 155(1): 75-84.
- [13] Pan W J, Chen Q, Zhu M T, et al. A Data-driven Fuzzy Information Granulation Approach for Battery State of Health Forecasting[J]. *Journal of Power Sources (S0378-7753)*, 2020, 475(228716): 1-12.
- [14] Sun X F, Zhong K, Han M. A Hybrid Prognosticstrategy with Unscented Particle Filter and Optimized Multiple Kernel Relevance Vector Machine for Lithium-ion Battery[J]. *Measurement (S0263-2241)*, 2020, 170(108679): 1-14.
- [15] 张伟, 黄卫民. 基于种群分区的多策略自适应多目标粒子群算法[J/OL]. *自动化学报*, 2020. <http://kns.cnki.net/kcms/detail/11.2109.tp.20200915.0941.002.html>.  
Zhang Wei, Huang Weimin. Multi-strategy Adaptive Multi-objective Particle Swarm Optimization Algorithm Based on swarm Partition[J]. *Acta Automatica Sinica*, 2020.<http://kns.cnki.net/kcms/detail/11.2109.tp.20200915.0941.002.html>.
- [16] Liu F K, Ma X M, An X S, et al. Urban Traffic Flow Prediction Model with CPSO/SSVM Algorithm under the Edge Computing Framework[J]. *Wireless Communications and Mobile Computing (S1530-8669)*, 2020: 8871998.
- [17] 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 Instrumentation*, 2017, 31(9): 1365-1371.