

DOI:10.3969/j.issn.1674-1951.2021.05.006

# 基于振动信号分析的滚动轴承寿命预测方法研究

Research on service life prediction on rolling bearings based on vibration signal analysis

谈智玲<sup>1</sup>, 陈才明<sup>1</sup>, 徐胜朝<sup>1</sup>, 吴志宏<sup>2</sup>, 宋寅<sup>2</sup>, 王朋飞<sup>3</sup>

TAN Zhiling<sup>1</sup>, CHEN Caiming<sup>1</sup>, XU Shengchao<sup>1</sup>, WU Zhihong<sup>2</sup>, SONG Yin<sup>2</sup>, WANG Pengfei<sup>3</sup>

(1.湖北华电襄阳发电有限公司,湖北 襄阳 441000;2.襄阳五二五泵业有限公司,湖北 襄阳 441004;

3.武汉理工大学 机电工程学院,武汉 430070)

(1.Hubei Xiangyang Power Generation Company Limited, Xiangyang 441000, China; 2.Xiangyang Wuerwu Pump Industry Company Limited, Xiangyang 441004, China; 3.School of Mechanical and Electrical Engineering, Wuhan University of Technology, Wuhan 430070, China)

**摘要:**滚动轴承剩余寿命预测问题具有多类别、多特征的复杂特性,传统的基于力学和概率统计的预测方法运用在工程实践中都较为困难。研究了基于振动信号分析的滚动轴承寿命预测方法。首先,将采集到的振动信号进行时域、频域和基于小波包样本熵的时频域特征提取;其次,通过皮尔逊相关分析筛选出与轴承寿命相关度较大的特征,作为轴承寿命预测的样本集;然后,把选择的特征参数作为输入,对改进后的粒子群优化算法-广义回归神经网络(PSO-GRNN)模型进行训练,构建轴承寿命预测模型;最后,将模型与反向传播(BP)神经网络模型和 PSO-GRNN 模型进行对比,试验证明电机滚动轴承寿命预测模型具备更强的稳定性和更高的精度。

**关键词:**特征提取;相关性分析;广义回归神经网络;粒子群优化算法;BP神经网络;滚动轴承;寿命预测

中图分类号:TH 133.33;TK 323

文献标志码:A

文章编号:1674-1951(2021)05-0036-09

**Abstract:** The prediction on residual life of rolling bearings is complex because of the multiple categories and multiple features. It is difficult to apply traditional prediction methods based on mechanics and probability statistics on engineering practices. In the following study, the service life of a rolling bearing was predicted based on vibration signal analysis. Firstly, feature extraction in time and frequency domains was made on the collected vibration signals and wavelet packet sample entropy. Then, the features with high correlation to the bearing's life span were selected by Pearson correlation analysis as the sample set of bearing life prediction. The selected characteristic parameters were taken as the inputs training the improved particle swarm optimization-General Regression Neural Network (PSO-GRNN) model to construct the bearing life prediction model. Comparing the results made by this bearing life prediction model, back propagation (BP) Neural Network model and PSO-GRNN model, the proposed model is verified to be more stable and accurate.

**Keywords:** feature extraction; correlation analysis; GRNN; particle swarm optimization algorithm; BP Neural Network; rolling bearing; life prediction

## 0 引言

电力企业浆液循环泵、氧化风机、球磨机等环保关键机泵可能发生的故障种类、征兆、机理各不相同,很难直接根据征兆对关键机泵设备进行寿命预测。但可针对关键机泵故障多发部件进行预测分析<sup>[1]</sup>。电动机作为环保关键机泵的核心动力设备

与易失效部件,如若发生故障,将会影响工厂其他生产设备的正常运转,甚至会导致整个生产系统瘫痪,给企业带来严重的经济损失。

滚动轴承寿命预测作为电机滚动轴承寿命管理的一个关键步骤,对于电机安全运行尤为重要。通过对电机滚动轴承进行可靠的寿命预测,能够准确掌握电机的运行状况,判断轴承的剩余寿命和故障情况,便于及时制定维修计划。

随着滚动轴承的寿命预测和状态监测理论与技术的不断发展,电机轴承寿命管理系统的预测结果变得更加精准。目前,滚动轴承寿命预测方法主

收稿日期:2021-01-20;修回日期:2021-04-10

基金项目:国家重点研发计划项目(2019YFB1707200);基于工业互联网平台的生产线数字孪生系统项目(TC19084DY)

要包括以下 3 种<sup>[2]</sup>。

(1)基于力学的滚动轴承寿命预测。该方法主要从滚动轴承的失效和破坏机理的动力学特征来预测滚动轴承的剩余使用寿命。文献[3]对轴承裂纹的扩展速度展开研究。文献[4]对滚动轴承的接触疲劳进行了研究。文献[5]等基于滚动轴承碎裂萌生理论对滚动轴承的寿命进行预测。这些方法普遍存在理论性强,建模困难的问题,在实际工程项目中应用较少。

(2)基于概率统计的滚动轴承寿命预测。该方法是指采用正态分布或威布尔分布模型等,使用大量的轴承试验数据训练模型参数,预测滚动轴承的失效率和可靠性。文献[6]提出了 Tallian 寿命理论,在 L-P 模型的基础上优化概率系数。文献[7]根据滚动轴承存在的无限寿命情况和材料的疲劳强度,构建了 Y-H 模型。文献[8]等提出基于动力学的轴承载荷分布模型。在工程实际应用中,不同轴承的工作状态存在差异,基于部分样本的概率很难满足所有轴承的实际状况,其使用局限性较强。

(3)基于信息技术的滚动轴承寿命预测。包含神经网络、模糊计算、专家系统、进化算法、粗糙集理论等人工智能方法,可以应用于不确定因素较多的电机滚动轴承寿命预测上。文献[9]等采用机器学习——支持向量机方法预测了滚动轴承的剩余寿命。文献[10]等使用神经网络算法预测了滚动轴承的剩余寿命。文献[11]等基于相关系数和反向传播(BP)神经网络算法搭建了滚动轴承的性能退化模型。

剩余寿命预测算法作为滚动轴承寿命管理系统中最为核心的部分,算法的准确性、检测速度和稳定性对滚动轴承寿命管理系统的性能起着关键性作用。针对滚动轴承剩余寿命预测问题具备多类别、多特征的复杂特性,本文通过提取能表征滚动轴承退化状态的特征值作为电机滚动轴承寿命预测的协变量,从而实现滚动轴承剩余寿命的精准预测。

### 1 基于小波包样本熵的时频域特征提取

小波包分解理论<sup>[12]</sup>是由 Wickerhauser 等在正交小波基的基础上提出的一种新的非线性和非平稳信号的分析方法。小波包分解理论将振动信号的时频平面划分得更加精细,对振动信号高频区域的分解分辨率要大大高于小波变换,能够自适应地选择合适的基函数,与原始振动信号匹配,进一步提高振动信号分解能力。

3 层小波包分解示意如图 1 所示,其中  $H$  是低频

分量,  $G$  是高频分量,  $S$  是原始振动信号。

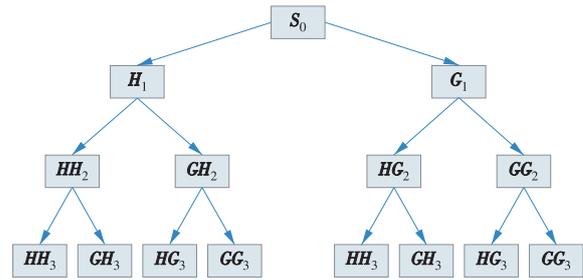


图 1 3 层小波包分解

Fig. 1 Three-layer wavelet package decomposition

样本熵<sup>[13]</sup>是表达时间序列的无规律程度和复杂度的定量描述方法。样本熵的值越大,说明滚动轴承振动信号的时间序列越复杂,系统越不稳定;反之表明时间序列自相似度越高,序列取值也更加规则。基于滚动轴承振动信号的特点,样本熵能够很好地对振动信号进行分析。鉴于小波包变换能够很好地分解滚动轴承振动信号,而且样本熵能够描述振动信号的复杂性和不规则性,本文把小波包变换与样本熵组合起来,提出一种基于小波包样本熵的时频域特征提取方法,其流程如图 2 所示。

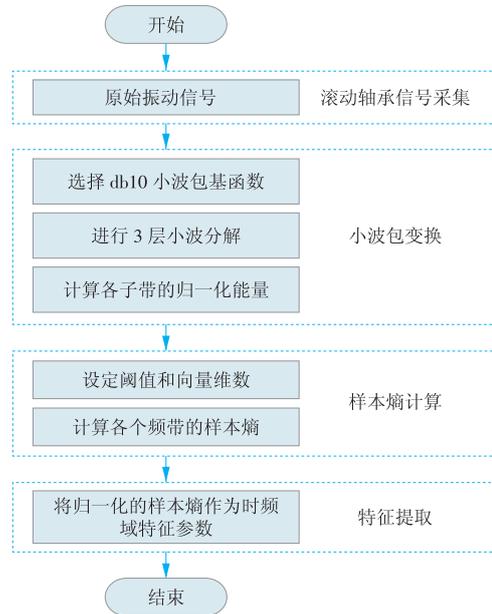


图 2 滚动轴承时频域特征提取流程

Fig. 2 Feature extraction in time and frequency domains for a rolling bearing

归一化后的 8 个频率子带的样本熵在滚动轴承全生命周期中的变化过程如图 3 所示,其中第 1, 4, 5, 6, 7, 8 子带的样本熵,在轴承正常工作时期保持稳定,随着轴承磨损加剧,产生突变并持续呈上升趋势;第 2 子带的样本熵随采样次数的增加产生的变化比较混乱,相关性很弱;第 3 子带的样本熵随着轴承的磨损加剧呈下降趋势,有一定相关性。

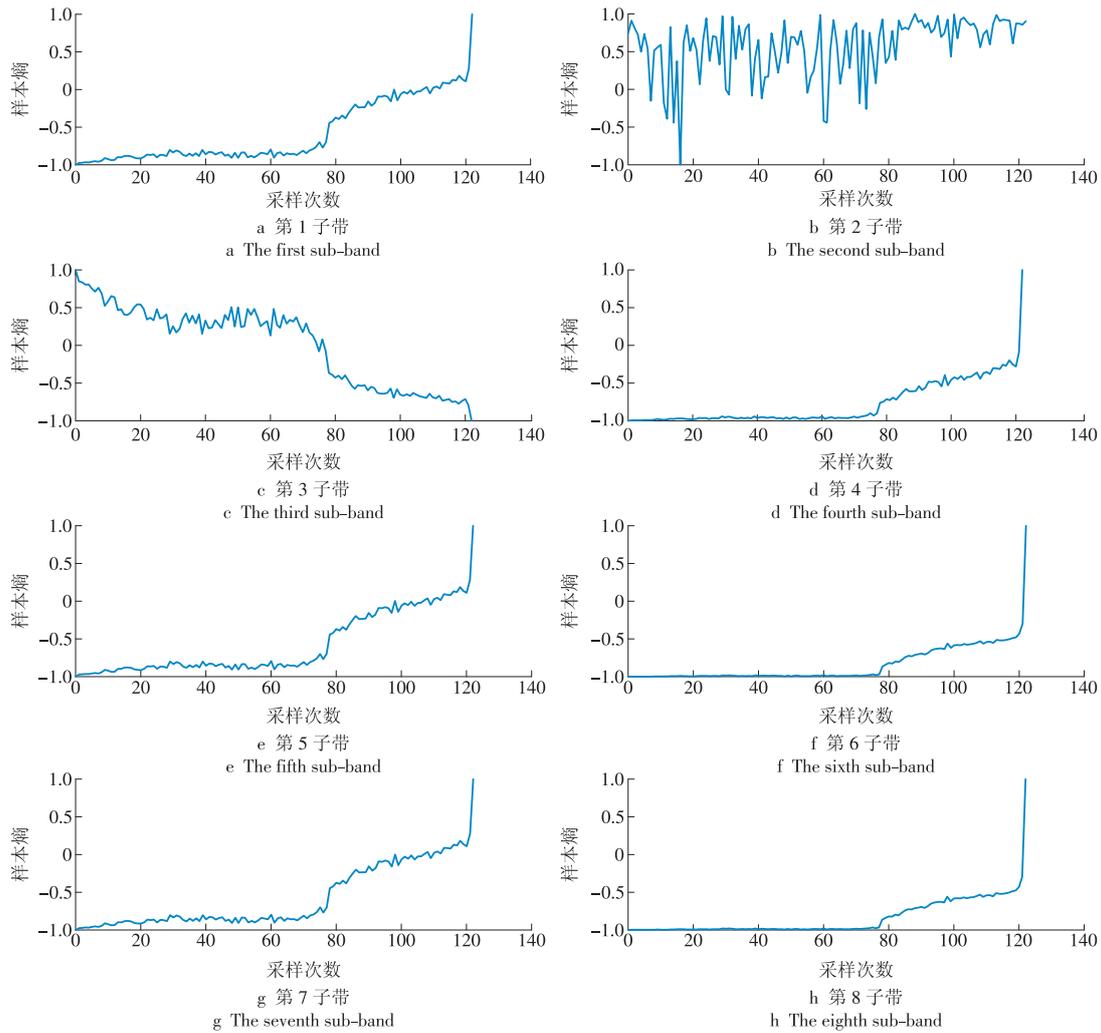


图3 基于小波包样本熵的振动信号时频域特征集

Fig. 3 Feature set of vibration signal in time and frequency domains based on wavelet packet sample entropy

### 2 基于皮尔逊相关分析的特征选择

通过时域、频域、时频域特征提取获得的振动信号特征参数多达20种,它们与滚动轴承的磨损状态及剩余寿命预测的相关程度各不相同。剔除这些与轴承剩余寿命预测相关性不大的特征参数,能提高寿命预测的精度和准确性。

皮尔逊相关分析法是目前常用的相关性分析法,它能衡量数据之间的关联程度<sup>[14]</sup>。数据X与数据Y之间的皮尔逊相关系数为

$$PCC(X, Y) = \frac{Cov(X, Y)}{\sqrt{D(X)D(Y)}}, \quad (1)$$

式中: $Cov(X, Y)$ 为数据X与Y的协方差; $D(X), D(Y)$ 分别为数据X与Y的方差。

$PCC(X, Y)$ 的取值范围为 $[-1, 1]$ ,其绝对值越大,表示数据X与Y的相关性越大;反之则表示数据的相关性越小。滚动轴承的振动信号的特征参数经过归一化处理,通过皮尔逊相关分析,获得这

些特征参数与滚动轴承剩余寿命值的皮尔逊相关系数PCC,从中筛选出PCC较大的特征参数。

图4展示了滚动轴承全生命周期中获取的振动信号的20种时域、频域及时频域特征参数与PCC的绝对值。

通过图4可以直观地发现这些特征参数与滚动轴承剩余寿命值的相关性强弱关系。图中 $\bar{X}, X_{rms}, C, K_r, C_L, C_w$ 分别表示时域特征参数中的绝对均值、均方根值、峰值因子、峭度值、裕度因子、偏斜度; $f_a, f_c, m_{sf}, v_f, R_{vf}, S$ 分别表示频域特征参数中的平均能量、重心频率、均方根频率、频率方差、频率标准差、信号能量。 $s_k (k = 1, 2, \dots, 8)$ 表示时频域特征中前8个小波包分解子频带的样本熵。

本文选取PCC的绝对值大于0.8的特征参数作为滚动轴承磨损分析和剩余寿命预测的特征参数集。由图4可以看出,绝对均值,均方根值,平均能量,均方根频率,频率标准差, $s_1, s_6, s_7$ 都是与滚动轴承寿命相关性较大的特征参数。

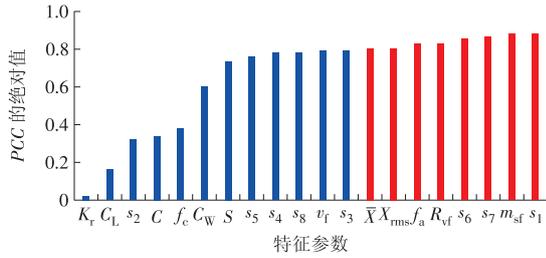


图 4 特征参数的皮尔逊相关系数值

Fig. 4 Pearson correlation coefficients of characteristic parameters

### 3 基于改进 PSO-GRNN 算法的轴承寿命预测模型

#### 3.1 GRNN 算法的改进

广义回归神经网络<sup>[15]</sup>(GRNN)是一种基于径向基神经网络改进的前馈式神经网络。当采集的轴承振动信号样本数据较少时,GRNN有很好的预测效果。

虽然经过皮尔逊相关分析筛选后的特征参数和滚动轴承剩余寿命的相关性都很强,但是在滚动轴承实际工作过程中,转速、动载荷、时域特征、频域特征及时频域特征等相关因素之间可能存在一定联系,这种联系会导致信息重复,造成 GRNN 算法的训练速度和预测准确度下降。为了消除这一影响,本文在输入层和模式层之间加入数据处理层,通过主成分分析(PCA)类似的方法对输入层的样本数据进行了压缩处理。以转动速度、工作时间、径向力、特征参数等作为输入的改进后的 GRNN 5 层网络结构如图 5 所示。其中,  $X(x_1, x_2, x_3, x_4, \dots, x_k)$  为神经元输入特征参数,  $d(d_1, d_2, \dots, d_p)$  为数据压缩处理结果,  $p(p_1, p_2, p_3, p_4, \dots, p_m)$  为神经元的传递函数,  $s(s_1, s_2)$  为模式层输出的神经元求和结果,  $Y$  为输出结果。

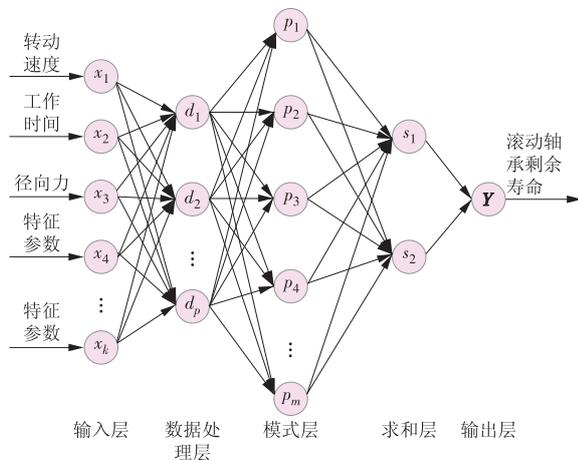


图 5 改进后的 GRNN 5 层网络结构

Fig. 5 Improved GRNN with five-layer network structure

假设输入层的观测值是  $X$ , 函数方程  $y$  是输出层的最大概率回归结果, 则  $y$  的期望为

$$\hat{Y} = E(y|X) = \frac{\int_{-\infty}^{+\infty} yf(X, y)dy}{\int_{-\infty}^{+\infty} f(X, y)dy}, \quad (2)$$

式中:  $\hat{Y}$  表示当输入为  $X$  时, 非独立变量  $Y$  的预测输出结果;  $f(X, y)$  为观测值  $X$  与其函数方程  $y$  的联合概率密度函数。

当  $f(X, y)$  符合高斯分布时, 得到估计密度函数  $\hat{f}(X, y)$  为

$$\hat{f}(X, y) = \frac{\sum_{i=1}^n Y_i \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right]}, \quad (3)$$

式中:  $Y_i$  是第  $i$  个样本的输出变量。将  $\hat{f}(X, y)$  代入式(2), 整理后得到 GRNN 的基本方程为

$$\hat{Y} = \frac{\sum_{i=1}^n Y_i \exp(-D_i^2 / (2\sigma^2))}{\sum_{i=1}^n \exp(-D_i^2 / (2\sigma^2))}, \quad (4)$$

式中:  $n$  为样本的数量,  $i = 1, 2, \dots, n$ ;  $\sigma$  为高斯函数的平滑因子;  $D_i^2$  为  $X$  和核函数中心  $X_i$  之间的欧氏距离, 其表达式为

$$D_i^2 = (X - X_i)^T (X - X_i). \quad (5)$$

在改进后的 GRNN 中, 神经元的层数固定为 5 层且每层神经元的个数可以由输入的样本确定, 即可以通过筛选后的特征参数确定。与 BP 神经网络相比, 它不需要设置神经元的层数及激励函数, 只需要设置平滑因子, 减少了寻优的参数数量。寻找最优的平滑因子  $\sigma$  是影响轴承寿命预测模型好坏的关键因素, 本文采用粒子群优化(PSO)算法来寻找最优的平滑因子。

#### 3.2 PSO 算法

PSO 算法<sup>[16]</sup>是一种群体智能优化算法, 该算法中赋予所有粒子记忆性, 在粒子移动的过程中, 通过与其他粒子共享信息以获得最优解。PSO 算法流程如图 6 所示。在这个过程中, 粒子的初始化及适应度函数的选择尤为重要。

(1) 粒子群的初始参数设置: 需要初始化粒子群中粒子的位置和速度并设置粒子群的种群大小  $n$ 、最大迭代次数  $m$ 、学习因子  $c_1$  和  $c_2$  等。本文选取的粒子种群大小  $n=30$ , 最大迭代次数  $m=1\ 000$ , 学习因子  $c_1=c_2=2$ , 粒子群搜索范围为  $(0.01, 2.00)$ , 惯性因子采用线性递减的权值策略为其赋值。

(2) 粒子群的适应度函数: 适应度函数用均方根误差  $RMSE$  表示, 即滚动轴承寿命预测模型的输

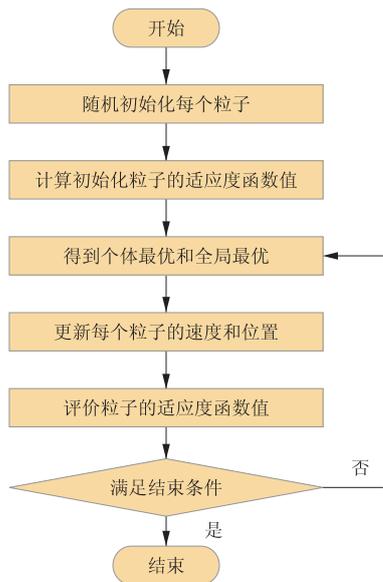


图 6 PSO 算法流程  
Fig. 6 PSO algorithm flow

出值与期望值之间的标准差,其表达式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - T'_i)^2}{n}}, \quad (6)$$

式中:  $T_i$  和  $T'_i$  分别表示第  $i$  个样本的输出值与期望值。

PSO 寻优的过程即寻找  $RMSE$  最小值的过程。某次优化过程中均方根误差  $RMSE$  随平滑因子在 (0.01, 2.00) 取值的变化过程如图 7 所示,最后得到平滑因子为 0.62 时,均方根误差  $RMSE$  最小,即其为输出的最优的平滑因子。

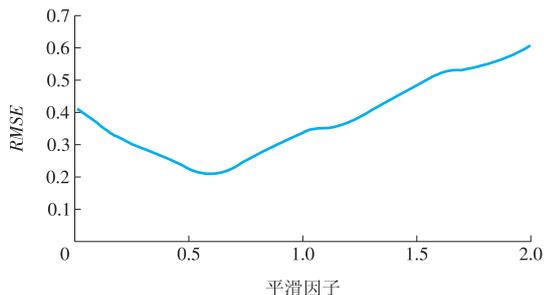


图 7  $RMSE$  随平滑因子的变化曲线  
Fig. 7 Curve of  $RMSE$  varied with the smoothness factor

### 3.3 滚动轴承剩余寿命预测模型

本文建立的滚动轴承剩余寿命预测模型架构如图 8 所示。具体步骤如下。

第 1 步:滚动轴承振动信号采集,对获取的振动信号进行预处理,主要包括去空值和剔除错点。

第 2 步:对预处理后的振动信号进行特征提取,本文采用小波包样本熵特征提取方法,将小波包分解后的 8 个子频带的样本熵作为时频域特征参数。

第 3 步:通过皮尔逊相关分析法,筛选出与滚动

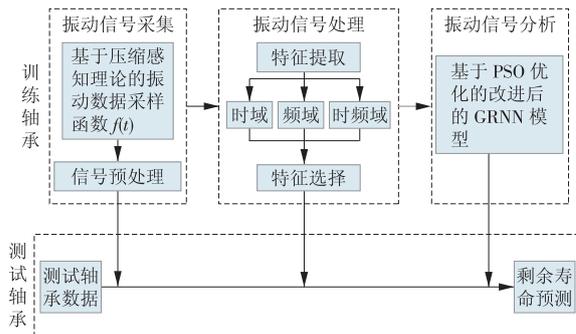


图 8 滚动轴承剩余寿命预测模型架构  
Fig. 8 Framework of residual life prediction model for antifriction bearing

轴承剩余寿命相关性较强的特征参数,能显著提高滚动轴承寿命预测的准确性。

第 4 步:利用 PSO 算法求出最优的平滑因子,建立优化后的 GRNN 模型,再将筛选后的特征参数、转速、径向力等作为学习样本,输入模型中进行训练,建立基于改进 PSO-GRNN 的轴承寿命预测模型。

第 5 步:将第 1 步获取的实时振动数据,通过信号预处理和特征处理后输入到优化后的 GRNN 模型中得到滚动轴承的预测剩余寿命。

### 4 滚动轴承寿命预测结果分析

本文选择滚动轴承的转动速度、工作时间、径向力、特征参数等作为学习样本的输入,借助 Matlab 分析工具对 BP 神经网络模型和 PSO-GRNN 模型进行训练,分别得到基于 BP 神经网络和 PSO-GRNN 模型的滚动轴承寿命预测模型。在获取滚动轴承振动信号测试样本数据时,选取 LDK UER204 滚动轴承作为试验对象,水平和垂直方向的加速度传感器固定在轴承外圈上,从而采集轴承振动信息。试验装置如图 9 所示。

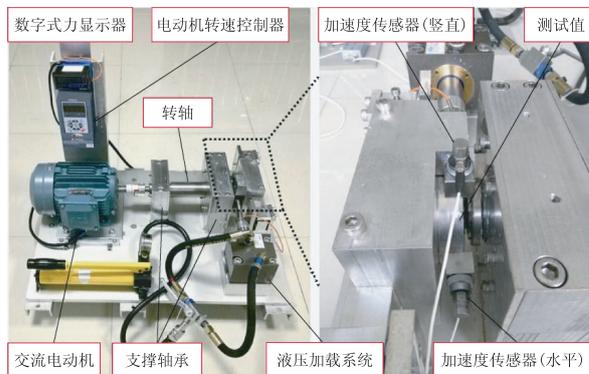


图 9 轴承振动信号采集试验装置  
Fig. 9 Bearing vibration signal acquisition and test device

为避免试验出现单一性结果,通过试验装置中的液压加载系统与电动机转速控制器搭配不同的转速与载荷,设定了 3 种工况进行样本参数的提取,

见表 1。

本文选取了在试验装置稳定运转时,试验轴承

表 1 测试样本参数

Tab. 1 Parameters of the test sample

工况	转速/(r·min <sup>-1</sup> )	载荷/kN
1	2 100	12
2	2 250	11
3	2 400	10

在正常状态、外圈故障、保持架断裂和内圈磨损 4 种典型状态下的各项数据,整理其时域与频域信号波形如图 10 所示。其中左侧为时域信号波形图,右侧为对应的频域信号波形图。

经过 PSO-GRNN 模型训练后,轴承时域和频域的重构信号波形如图 11 所示,其中左侧为时域信号波形图,右侧为对应的频域信号波形图。

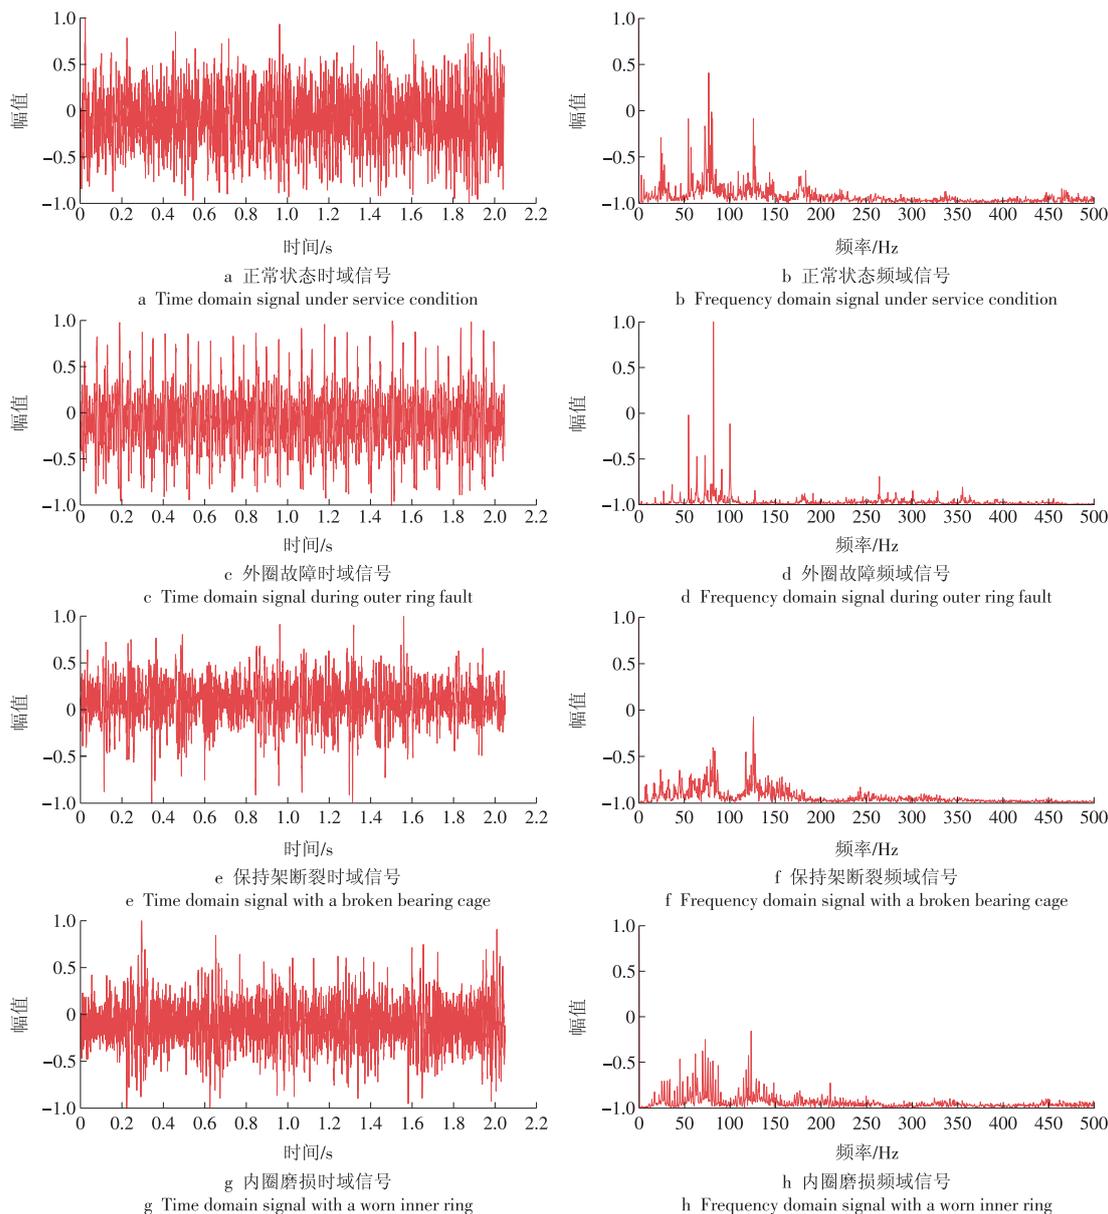


图 10 4 种状态下轴承的时域和频域信号波形

Fig. 10 Time and frequency domains signal waveforms of the bearing in four states

为了验证本文基于改进 PSO-GRNN 模型的效果,在表 1 所示的 3 种不同转速和载荷工况下,采集试验用滚动轴承全生命周期的振动信号,依照时间顺序将采集到的振动信号均匀分为多组样本数据。

将上述样本数据分别利用 BP 神经网络、PSO-

GRNN 模型、改进后的 PSO-GRNN 模型各自进行运算,得到试验用滚动轴承的预期剩余寿命,与实际使用寿命进行对比,得到 3 种模型在 3 种工况下的剩余寿命预测结果,如图 12 所示。

其中横坐标为试验轴承各工况的采集时间,纵

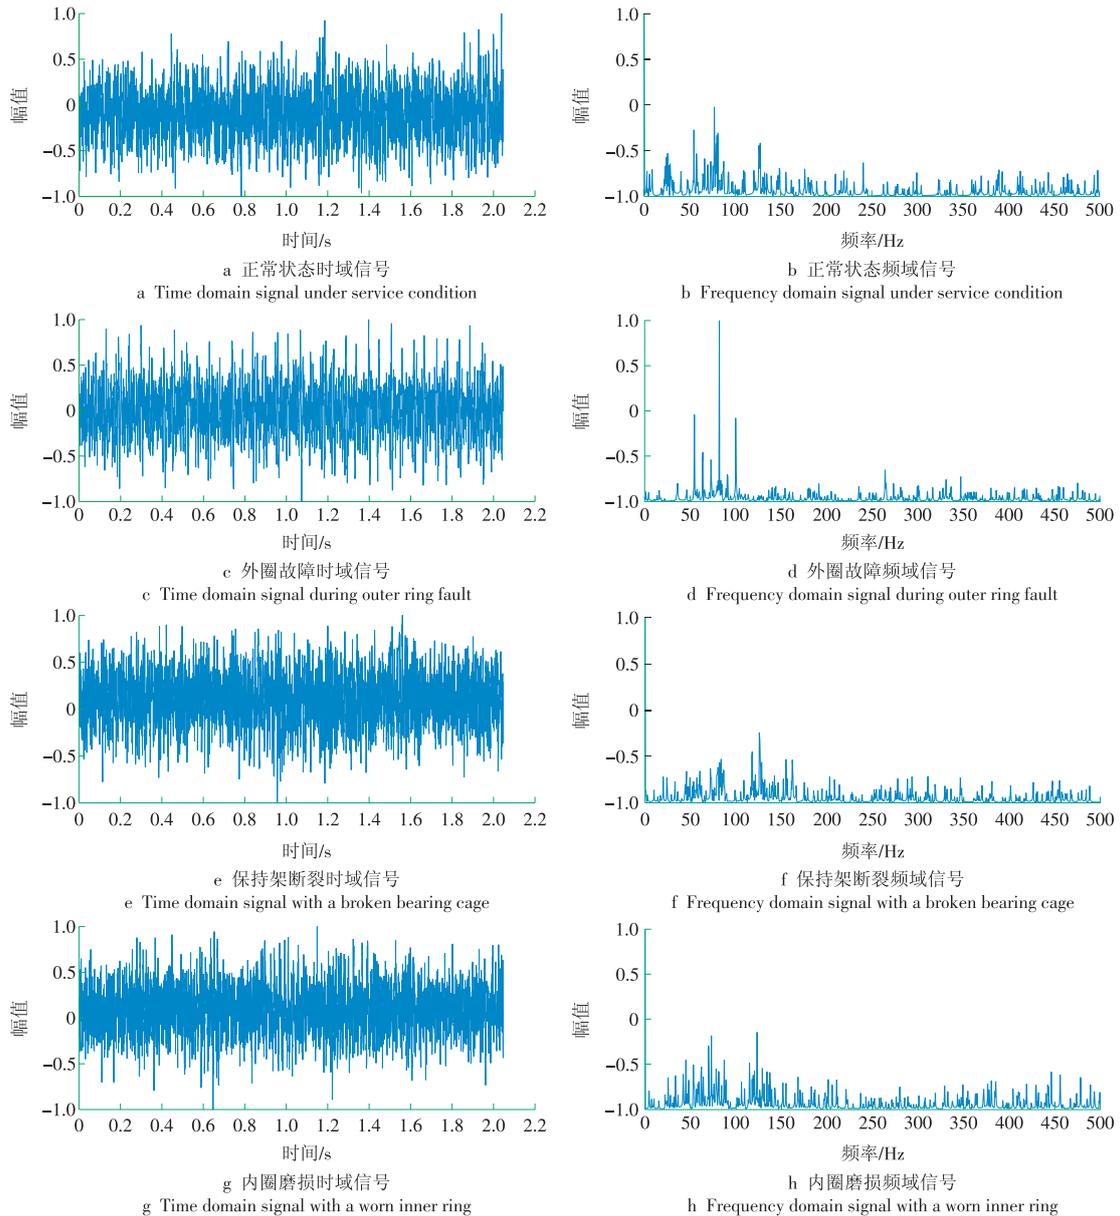


图 11 经过 PSO-GRNN 模型训练后轴承的时域和频域信号波形

Fig. 11 Signal waveforms of the bearing in time and frequency domains after the training of PSO-GRNN

坐标为剩余寿命百分比。

由图 12 可知, BP 神经网络模型预测值的波动情况最为剧烈, 由于 BP 神经网络容易陷入局部最优, 从而使预测结果不准确。

GRNN 神经网络在学习速度、分类能力和逼近能力等方面均优于 BP 神经网络, 但仍存在局部预测值波动较大的情况。

改进后的 PSO-GRNN 模型的剩余寿命预测性能最好, 预测值波动最小, 且寿命后期的误差很小, 这对轴承寿命预测尤为重要, 能够给更换零部件提供更准确的参考时间。

为了定量分析剩余寿命预测算法的优劣, 以均方根相对误差  $RMSE_r$  为指标衡量不同预测算法的预测精度, 其表达式为

$$RMSE_r = \sqrt{\frac{\sum_{i=1}^n \left(1 - \frac{T'_i}{T_i}\right)^2}{n}} \quad (7)$$

3 种模型在 3 种工况下的滚动轴承预测寿命与实际剩余寿命的均方根相对误差见表 2。

由表 2 可见, 改进后的 PSO-GRNN 模型的均方根相对误差在这 3 种模型中最小, 这也表明了改进后的 PSO-GRNN 模型的寿命预测值比 BP 神经网络模型和 PSO-GRNN 模型更加准确和稳定。

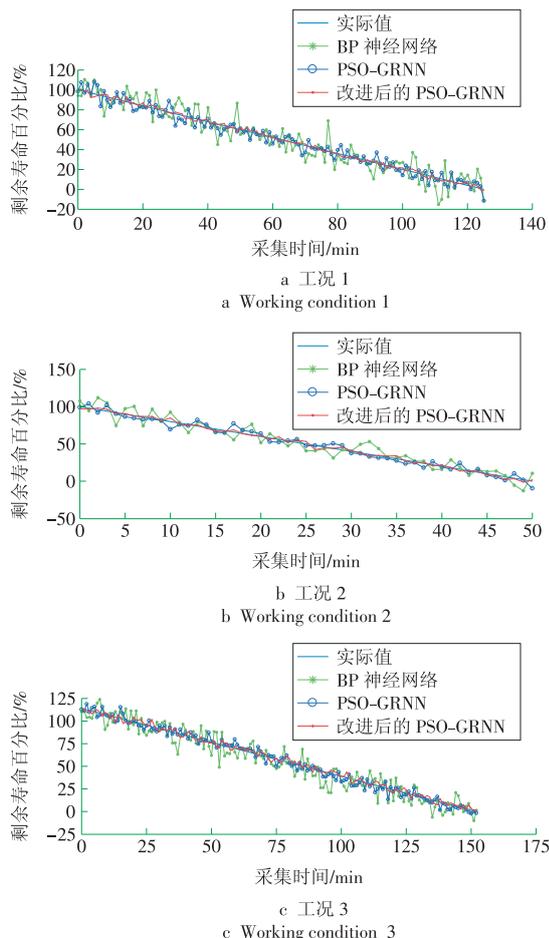


图 12 3 种模型在 3 种工况下的剩余寿命预测结果

Fig. 12 Residual life predicted by three models under three working conditions

表 2 不同工况下预测值与实际值的均方根相对误差

Tab. 2 RMSE between the predicted and the measured value with different working conditions %

工况	BP 神经网络模型	PSO-GRNN 模型	改进后的 PSO-GRNN 模型
1	6.08	4.77	2.31
2	6.75	4.61	2.19
3	5.84	5.08	2.01

### 5 结束语

本文对采集到的滚动轴承振动信号进行时域、频域、基于小波包样本熵的时频域特征参数提取,将提取到的振动信号的高维特征参数通过皮尔逊相关性分析进行筛选,选择出与滚动轴承剩余寿命值相关性较大的特征参数集。将筛选后的特征参数与加工参数作为学习样本,利用基于 PSO 优化的改进后的 GRNN 算法构建滚动轴承剩余寿命预测模型并与其他 2 种方法进行对比,验证了本文提出的滚动轴承寿命预测模型具有更高的准确性及更好的稳定性。

### 参考文献:

[1]沈长青. 旋转机械设备关键部件故障诊断与预测方法研究[D]. 合肥:中国科学技术大学,2014.

[2]张小丽,陈雪峰,李兵,等. 机械重大装备寿命预测综述[J]. 机械工程学报,2011,47(11):100-116. ZHANG Xiaoli, CHEN Xuefeng, LI Bing, et al. Review of life prediction for mechanical major equipments [J]. Journal of Mechanical Engineering, 2011, 47(11): 100-116.

[3]PARIS P C, ERDOGAN F. A critical analysis of crack propagation laws [J]. Journal of Basic Engineering, 1963, 85 (4):528-534.

[4]ANDREIKIV O E, LESIV R M, LEVYTS'KA N M. Crack growth in structural materials under the combined action of fatigue and creep (review) [J]. Materials Science, 2009, 45 (1):1-17.

[5]MAKKONEN M. Predicting the total fatigue life in metals [J]. International Journal of Fatigue, 2009, 31(7):1163-1175.

[6]TALLIAN T. Weibull distribution of rolling contact fatigue life and deviations therefrom [J]. ASLE Trans, 1962, 5(5):183-196.

[7]ZHAO Y X, LIANG H. Modeling of the probabilistic fatigue S-N curves using the two parameter Weibull distribution [J]. Journal of Mechanical Engineering, 2015, 51(20):208-212.

[8]唐云冰,高德平,罗贵火. 航空发动机高速滚珠轴承力学特性分析与研究 [J]. 航空动力学报, 2006(2):354-360. TANG Yunbing, GAO Deping, LUO Guihuo. Research of aero - engine high - speed ball bearing [J]. Journal of Aerospace Power, 2006(2):354-360.

[9]LU C, CHEN J, HONG R, et al. Degradation trend estimation of slewing bearing based on LSSVM model [J]. Mechanical Systems & Signal Processing, 2016, 76-77:353-366.

[10]CHOI S, PAZOUKI E, BAEK J, et al. Iterative condition monitoring and fault diagnosis scheme of electric motor for harsh industrial application [J]. IEEE Transactions on Industrial Electronics, 2015, 62(3):1760-1769.

[11]邱晓梅,隋文涛,王峰,等. 基于相关系数和 BP 神经网络的轴承剩余寿命预测 [J]. 组合机床与自动化加工技术, 2019(4):63-65. QIU Xiaomei, SUI Wentao, WANG Feng, et al. Remaining life prediction of bearing based on correlation coefficient and BP neural network [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2019(4):63-65.

[12]张永建,孙燕芳,邢龙超. 基于小波包分解的滚动轴承故障诊断方法的研究 [J]. 煤矿机械, 2014, 35(5):256-258. ZHANG Yongjian, SUN Yanfang, XING Longchao. Research of rolling bearing fault diagnosis based on wavelet-packet decomposition method [J]. Coal Mine Machinery, 2014, 35 (5):256-258.

- [13]何勇,张祥金,姚宗辰.改进样本熵最优小波包阈值选择算法在信号降噪中的应用[J].兵器装备工程学报,2019,40(3):149-154.  
HE Yong, ZHANG Xiangjin, YAO Zongchen. Improved optimal threshold selection algorithm applied to denoising [J]. Journal of Ordnance Equipment Engineering, 2019, 40 (3): 149-154.
- [14]车远宏,贾雍,汤卓,等.皮尔逊相关系数在风电功率组合预测中的应用[J].广西电力,2016,39(3):50-53.  
CHE Yuanhong, JIA Yong, TANG Zhuo, et al. Application of pearson correlation coefficient in wind power combination prediction [J]. Guangxi Electric Power, 2016, 39(3):50-53.
- [15]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.  
ZHANG Chenlong, ZHENG Kai, LIU Jie. Prediction method of bearing remaining useful life based on wavelet packet energy spectrum and improved FOA-GRNN [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(7):73-76,80.
- [16]金亚军,张丹,隋文涛,等.基于粒子群优化神经网络的滚动轴承剩余寿命预测[J].组合机床与自动化加工技术,2020(8):64-66,70.  
JIN Yajun, ZHANG Dan, SUI Wentao, et al. Prediction of

rolling bearing residual life based on particle swarm optimization and neural network [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020 (8) : 64-66,70.

(本文责编:张帆)

#### 作者简介:

谈智玲(1973—),男,湖北孝感人,工程师,从事发电及环保工艺系统设施管理等方面的工作(E-mail:xydctzl@163.com)。

陈才明(1971—),男,湖北红安人,高级工程师,从事发电及环保工艺系统设施管理等方面的工作(E-mail:xyfdccm@163.com)。

徐胜朝(1972—),男,安徽安庆人,工程师,从事发电及环保工艺系统设施管理等方面的工作(E-mail:xsxcf@163.com)。

吴志宏(1974—),男,湖北潜江人,正高级工程师,从事通用机械泵行业产品研发及工艺技术管理等方面的工作(E-mail:wuzhiah@yeah.net)。

宋寅(1986—),男,湖北襄阳人,工程师,从事通用机械泵行业产品研发及工艺技术管理等方面的工作(E-mail:82006465@qq.com)。

王朋飞(1995—),男,河南漯河人,在读硕士研究生,从事工业物联网等方面的研究(E-mail:1033314493@qq.com)。