

## Research on Rolling Bearing Fault Prediction Based on Evolutionary Neural Network

Li Yunfei   Ge Jianghua\*   Zheng Zhijie   Guo Haile   Niu Yangyang  
Xu Haifeng

Harbin University of Science and Technology, Harbin

**Abstract:** In the process of fault prediction for traditional neural networks, there is a problem that the learning efficiency is low, the network weight is difficult to determine and it is easy to fall into the local extremum. This paper proposes a rolling bearing fault prediction method based on evolutionary neural network. The Otsu-EWT signal denoising method is proposed. The maximum inter-class variance method (Otsu) is to calculate the inter-class variance of the target and the background and use the maximum value as the threshold for image partitioning. EWT can adaptively divide the spectral range of the spectrogram. The corresponding bandpass filter is constructed on each divided frequency band to reduce noise; the root mean square index is sensitive to early faults, and the feature extraction is performed by the root mean square index; the genetic algorithm has good global search ability and BP. Based on the local search ability of neural network, a prediction method of rolling bearing fault based on evolutionary neural network is proposed. Experimental results show that this method can effectively predict bearing faults.

**Key words:** Rolling bearing; Fault prediction; Genetic algorithm; Root mean square;

Evolutionary neural network

Received: 2019-07-31; Accepted: 2019-08-12; Published: 2019-09-02

# 基于进化神经网络的滚动轴承故障预测研究

李云飞 葛江华\* 郑智杰 郭海乐 牛阳阳 徐海锋

哈尔滨理工大学, 哈尔滨

邮箱: wypl@163.com

**摘 要:** 在针对传统的神经网络在故障预测过程中, 存在学习效率低, 网络权值难以确定且容易陷入局部极值的问题, 本文提出基于进化神经网络的滚动轴承故障预测方法。首先, 提出 Otsu-EWT 信号降噪方法, 最大类间方差法 (Otsu) 是通过计算目标与背景类间方差并将最大值作为图像划分阈值的标准, EWT 能对频谱图频谱区间进行自适应划分, 在各划分的区间频率带上构建相应的带通滤波器进行降噪; 其次, 根据均方根指标对早期故障的敏感性, 对均方根指标进行故障特征提取; 最后应用遗传算法的具有良好的全局搜索能力和 BP 神经网络的局部搜索能力相结合, 提出基于进化神经网络的滚动轴承故障预测方法, 实验结果表明, 本方法能够有效地对轴承的故障进行预测。

**关键词:** 滚动轴承; 故障预测; 遗传算法; 均方根; 进化神经网络

收稿日期: 2019-07-31; 录用日期: 2019-08-12; 发表日期: 2019-09-02

Copyright © 2019 by author(s) and SciScan Publishing Limited.

This article is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/).

<https://creativecommons.org/licenses/by-nc/4.0/>



## 1 引言

国内外所有大型的机械设备的运行环境日趋恶劣，滚动轴承作为旋转机械里必不可少的零件，所以一个轴承状态的好坏也变得格外重要。当轴承运行出现故障时，机械设备就会出现振动和较大的噪声，严重的可能导致整个生产系统瘫痪，造成的经济损失也是无法预估的 [1]。因此，对滚动轴承进行实时状态检测人和故障检测，保障设备的正常运行，避免事故的发生具有重大的意义 [2]。

在每个轴承实际工作中，由于外界环境因素的变化和干扰，传统的时域频域分析方法已经满足不了对这种复杂工况的分析。经验小波变换可以克服传统信号分解方法存在的模式混叠、端点效应、过包络、欠包络、不能自适应调节窗函数等问题 [3]，然而现有的频谱划分采用调试的方法确定边界，缺乏效率与准确性。经验小波变换的实质是通过自适应的划分信号的频谱，并相应地在每个区间构造带通滤波器，实现对信号中不同的调幅 - 调频成分的提取，为后续信号重构和 Hilbert 变换提供基础。为此，Gilles 首次提出了经验小波变换方法（Empirical Wavelet Transform，简称 EWT），经验小波变换由于自身的特性能够对频谱图进行自适应区间的划分，并且在每个划分出的区间能够构建自己独立、正交的带通滤波器组，来提取具有紧支撑特性的调幅 - 调频分量 [4]。邓飞跃等 [5] 应用自适应频率窗 EWT 方法，准确提取强噪声背景下滚动轴承故障特征。Luo 等 [6] 提出 AR-EWT（the Auto-regressive Empirical Wavelet Transform，简称 AR-EWT）方法，在自回归功率谱中抑制非平稳因子，正确地分解出添加有

高斯白噪声和非静止分量的信号。EWT方法中核心部分是信号频谱的划分[7]，划分区间的好坏直接影响降噪效果的优劣，影响信号分解的效果。

本文提出一种 Otsu-EWT 方法，通过基于最大类间方差的频谱自适应划分进行经验小波变换，更优地实现信号的分解。将降噪后处理的数据导入建立好的进化神经网络模型中进行故障预测。本文采用粒子群的全局搜索能力和 BP 神经网络的局部搜索能力先后结合，通过网络模型搭建，进行训练，寻找到最优解。BP 神经网络是根据误差来进行反向传播，通过对每层神经网络的权值和阈值的修改[8]，来降低输出和期望之间的误差，导致整个过程学习效率比较低。针对 BP 神经网络的权值和阈值选取问题和训练效率低的问题，本文将遗传算法结合到 BP 神经网络，可以根据每次训练的误差值进行自适应选取隐含层的节点数，选取出最佳的训练参数，选取最佳权值阈值矩阵，从而提高神经网络的训练精度[9]。基于进化的神经网络结合了 BP 神经网络和遗传算法的双重优点，并对 BP 神经网络的缺点进行了优化和改进，可以为故障预测领域提供更加有效的理论支撑和更为丰富的信息。

综上所述，首先提出 Otsu-EWT 降噪方法，通过 EWT 自适应地对信号频谱进行划分，克服模态混叠等问题。然后应用进化神经网络的故障预测模型进行性能衰退预测，有效划分滚动轴承全生命周期的故障阶段。

## 2 Otsu-EWT 降噪

经验小波变换的主要目的就是能够将轴承的频谱图进行自适应的划分，并在划分区间上建立相应的带通滤波器组，对信号进行降噪，为之后的进化神经网络预测提供理论支撑。

### 2.1 确定区间并构建区间带通滤波器

经验小波变换可以克服传统信号分解方法存在的模式混叠、端点效应、过包络、欠包络、不能自适应调节窗函数等问题，然而现有的频谱划分采用调试的方法确定边界，缺乏效率与准确性。Otsu-EWT 通过基于最大类间方差的频谱自适应划分进行经验小波变换，更优地实现信号的分解。

最大类间方差法 (Otsu) 是通过计算目标与背景类间方差并将最大值作为图像划分阈值的标准。

对于给定图像, 假设像素数是  $N$ , 灰度取  $[0, L-1]$ , 则有:

$$p_i = n_i / N, \quad i = 0, 1, 2, \dots, L-1 \quad (1)$$

$$\sum_{i=0}^{L-1} p_i = 1$$

式中  $n_i$  是素数,  $p_i$  是像素点出现的概率。图像根据阈值  $k$  分为目标和非目标两部分  $C_0$  与  $C_1$ , 分别为灰度值在  $[0, K]$  和  $[K+1, L+1]$  中的像素构成, 给定图像的均值可以表示为:

$$u_k = \sum_{i=0}^{L-1} ip_i \quad (2)$$

$C_0$  与  $C_1$  的均值为:

$$u_0 = \sum_{i=0}^k ip_i / w_0 \quad (3)$$

$$u_1 = \sum_{i=k+1}^{L-1} ip_i / w_1 \quad (4)$$

类间方差可以表示为:

$$\sigma_B^2 = w_0 (u_0 - u_k)^2 + w_1 (u_1 - u_k)^2 = w_0 w_1 (u_0 - u_1)^2 \quad (5)$$

在  $[0, L-1]$  区间内根据  $\sigma_B^2$  最大的原则对  $k$  进行取值, 通常情况下给定图像中类的个数是未知的, 因此筛选出的阈值数也是未知的, 可以假设目标数量为  $M$  Count, 则  $C$  确定的阈值为  $[T_1, T_2, \dots, T_{C-1}]$ 。

为了提高 Otsu 的自适应性, 引入  $SF$  作为循环结束的判定准则确定阈值的数量,  $SF$  的取值范围为  $[0, 1]$ , 如下式所示:

$$SF = \frac{\sigma_B^2}{V_T} \quad (6)$$

$V_T$  是给定图像的总方差。 $SF$  越大表明类间的差别越大, 当  $SF$  近似于 1 时, 类间方差应为最大值, 阈值数也可以确定, 目标被区分出来。

依据 EWT 确定好区间边界, 依据小波变化的方式, 在依据边界划分出来的区间构建带通滤波器, 周期为  $2\pi$ , 只研究区间  $[0, 2\pi]$ , 可以得到:

$$|\hat{\phi}_1(\omega)|^2 + |\hat{\phi}_1(\omega - 2\pi)|^2 + \sum_{n=1}^M [|\hat{\psi}_n(\omega)|^2 + |\hat{\psi}_n(\omega - 2\pi)|^2] = 1 \quad (7)$$

式中,  $\hat{\psi}_n$  为经验小波函数,  $\hat{\phi}_n$  为经验尺度函数, 在  $T_n$  不重叠的情况下也同样适用于  $T_n$ , 即如下式所示:

$$\begin{aligned} \tau_n + \tau_{n+1} < \omega_{n+1} - \omega_n &\iff \gamma \omega_n + \gamma \omega_{n+1} \\ &< \omega_{n+1} - \omega_n \iff \gamma \frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n} \end{aligned} \quad (8)$$

经验小波变换的细节系数如下:

$$\begin{aligned} \omega_f^\varepsilon(n, t) &= (f, \psi_n) = \int f(\tau) \overline{\psi_n(\tau - t)} dt \\ &= [\hat{f}(\omega) \overline{\hat{\psi}_n(\omega)}] \end{aligned} \quad (9)$$

经验小波变换的近似系数如下:

$$\begin{aligned} \omega_f^\varepsilon(0, t) &= (f, \phi_1) = \int f(\tau) \overline{\phi_1(\tau - t)} dt \\ &= [\hat{f}(\omega) \overline{\hat{\phi}_1(\omega)}] \end{aligned} \quad (10)$$

由以上可以得到经验模态函数如下:

$$\begin{aligned} f_0(t) &= \omega_f^\varepsilon(0, t) * \phi_1(t) \\ f_k(t) &= \omega_f^\varepsilon(k, t) * \psi(t) \end{aligned} \quad (11)$$

### 3 调幅 – 调频分量筛选指标

基于有量纲分析的故障诊断主要是从时域方面对所要研究的对象进行分析诊断的, 主要包含均值、均方根值和方差三种形式的幅域参数。

(1) 均值:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (12)$$

(2) 均方根值 (有效值)  $X_{rms}$ :

$$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2} \quad (13)$$

(3) 方根幅值  $X_r$ :

$$X_r = \left[ \frac{1}{N} \sum_{i=1}^N \sqrt{|X_i|} \right]^2 \quad (14)$$

有量纲指标对故障程度反应较为敏感, 通常适用于中度至重度损伤的故障诊断与预测, 受外部环境影响较大, 且易受到复合故障的影响。

无量纲指标是根据有量纲指标的比值转化而来, 反映的是频率密度函数的

形状, 对于时间序列信号  $X=\{x_i\}$ ,  $i=1, 2, \cdots, n$ , 本文应用的无量纲幅域参数如波形指标  $S_f$ 、峰值指标  $C_f$ 、脉冲指标  $I_f$ 、裕度指标  $CL_f$ 、峭度指标  $K_r$ 。

(1) 波形指标  $S_f$ :

$$S_f = \frac{X_{rms}}{|\bar{X}|} \quad (15)$$

(2) 峰值指标  $C_f$ :

$$C_f = \frac{X_{max}}{X_{rms}} \quad (16)$$

(3) 脉冲指标  $I_f$ :

$$I_f = \frac{X_{max}}{|\bar{X}|} \quad (17)$$

(4) 裕度指标  $CL_f$ :

$$CL_f = \frac{X_{max}}{X_r} \quad (18)$$

(5) 峭度指标  $K_r$ :

$$K_r = \frac{\beta}{X_{rms}^4} \quad (19)$$

无量纲指标的优点可以归纳为: ①具有反映故障特征的能力; ②几乎与振动信号绝对水平无关; ③对不同类型故障存在不同敏感性; ④对复合并发故障不敏感; ⑤基本不受工况、载荷、转速等变化的影响。

## 4 基于进化神经网络的故障预测

BP 神经网络是人工神经网络的一种模型, 每个神经元之间通过权值来联接, 其网络结构也是经典的三层网络, 由输入层、隐含层和输出层构成。BP 神经网络的权值具有可调性, 结构简单, 具有良好的非线性逼近和自我学习能力。

### 4.1 BP 神经网络原理

BP 神经网络是一种有监督的学习。BP 神经网络的实现过程分为两部分: 正向传播和逆向修正。在正向进行时, 从输入层到隐含层到输出层, 每层都有相应的函数训练样本, 并在输出层得到实际输出。若实际输出和期望输出误差比较大, 进行反向传播, 对权值和阈值进行修改, 从而降低误差, 得到最准确的

输出, 网络结构如图 1。




图 1 BP 神经网络结构

Figure 1 Structure of BP neural network

若有  $N$  个不同的输入  $(x_n, t_n) \in R^d \times R^m$ , 且拥有激活函数和  $H$  个隐含层节点数的 BP 神经网络可以表示为:

$$\sum_{j=1}^H \beta_j g [\omega_j^T x(n) + b_j] = (t) n \quad (20)$$

$$n=1, 2, \dots, N$$

上式简略表达如下所示:

$$H\beta = T \quad (21)$$

其中,  $H [\omega_1, \dots, \omega_H, b_1, \dots, b_H, x(1), \dots, x(N)] =$

$$\begin{Bmatrix} g[\omega_1^T x(1) + b_1] \cdots g[\omega_1^T x(1) + b_H] \\ \vdots \\ g[\omega_1^T x(N) + b_1] \cdots g[\omega_1^T x(N) + b_H] \end{Bmatrix}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \dots \\ \beta_H^T \end{bmatrix}, T = \begin{bmatrix} t_1^T \\ \dots \\ t_H^T \end{bmatrix}$$

$\omega_j$  代表输入层和第  $j$  个隐含层之间的输入权值向量,  $b_j$  是第  $j$  个隐含层神经元的偏置值,  $\beta_j$  是第  $j$  个隐含层与输出层之间的输出权值向量。

这里  $H^+$  是矩阵  $H$  的广义逆矩阵。确定训练样本集  $L$ , 隐含层神经元节点数  $H$  和激活函数  $g(\cdot)$ 。



- (1) 归一化网络权值和隐含层偏置值, 随机选取进行网络参数的初始化;
- (2) 对训练集样本的输入向量和期望输出向量在模型中进行离线训练;
- (3) 确定采用 BP 神经网络所需要实现的功能, 回归预测或分类;
- (4) 计算隐含层输出矩阵。根据公式 (12) 和公式 (13) 计算隐含层的输出矩阵  $H$ ;
- (5) 依据公式 (14), 用步骤 (4) 计算而得的  $H$  和训练样本期望输出值计算输出权值;
- (6) 计算实际输出和期望之间的误差, 进行反向传播, 对权值阈值进行修正。

## 4.2 遗传算法原理

遗传算法 (Genetic Algorithm, GA) 是由 Holland 于 1975 年提出的一个基于生物种群进化的算法。遗传算法是进化算法的一种, 是模仿大自然生物种群的进化和选优淘劣的过程, 不断提高种群对外界的适应能力, 该算法具有问题搜索空间广、个体编码方式多样、易于实现并行化、自我学习及自我组织等特点。遗传算法具有高鲁棒性和较好的适用性 [9]。

遗传算法主要包括初始化、交叉、变异、选取等。首先基于染色体的编码方式对种群进行初始化, 然后根据问题构建适应度函数。其次, 种群中每个个体都以指定的概率与其他个体交换部分基因, 并得到新的个体, 即交叉操作, 如图 2 所示。随后这些个体中的部分基因按照指定的概率进行突变, 即变异操作, 如图 3 所示。最终在交叉和变异操作以后, 每个个体都得到进化并得到新的染色体结构, 经过种群多次迭代, 得到最好的个体。




图 2 交叉操作

Figure 2 Cross-over operation




图 3 变异操作

Figure 3 Mutation operation

### 4.3 基于进化神经网络的故障预测

进化神经网络的研究主要在结构和算法两方面。BP 神经网络模型的工作原理是一种自修改的反向传播的模型。BP 神经网络是一个从输入到输出的高度的非线性映射的过程，具有较好的容错性和自适应性。进化神经网络是一种使用遗传算法原理，确定选取 BP 神经网络中不同神经元之间的权值的方法，算法原理如图 4 所示。染色体表示编码即每个基因呈现神经网络不同神经元之间的权重，染色体由图 5 所示的一系列基因构建，例如，染色体序列中的第一个基因是  $w_{15}$ ，是连接神经元 1 和神经元 5 之间的权重，第二个基因是  $w_{16}$ ，连接神经元。

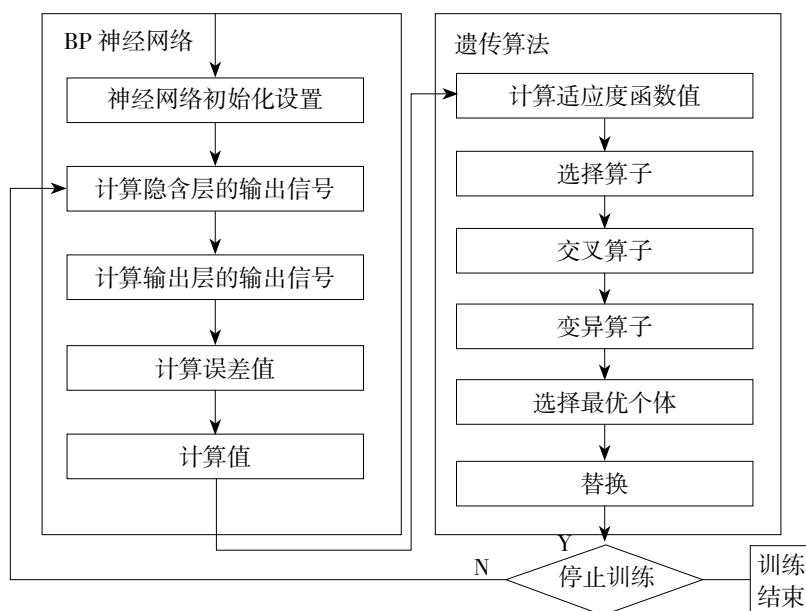


图 4 进化神经网络算法结构图

Figure 4 Structure diagram of Evolving network (ENN) algorithm




图5 染色体编码图

Figure 5 Chromosome encoding graph

根据以上各个算法流程，得到本文整体流程如图6所示，具体过程如下：

- (1) 通过 EWT 频率带区间划分个数，自适应划分 Fourier 频谱；
- (2) 降噪后的数据设  $X = (x_1, \dots, x_p)$ ,  $Y = (y_1, \dots, y_m)$  作为进化神经网络的训练集和测试集，通过遗传算法不断修正主成分数和各自权重；
- (3)  $w_i$  为输入层和隐含层之间的权值， $\beta$  为隐含层与输出层之间的初始权值；
- (4) 调整权值，计算网络误差：

$$e = \frac{1}{2} (y - \tilde{y})^2 \quad (22)$$

根据误差，求导并结合激活函数：

$$\tilde{\beta}_i = \beta_i + \eta t_i e' \quad (23)$$

- (5) 通过残差闭环反馈整个训练过程。

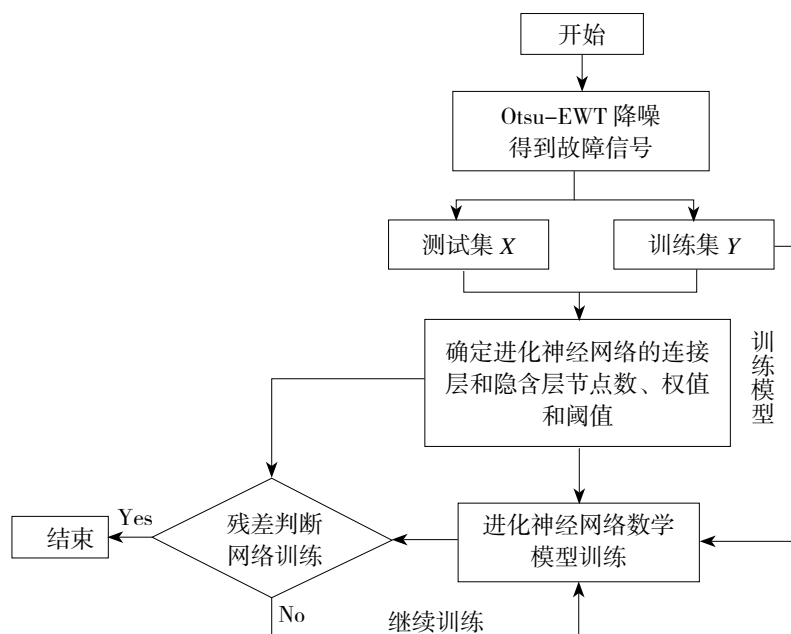



图 6 进化神经网络算法流程图

Figure 6 Evolving network(ENN) algorithm flow chart

## 5 验证

### 5.1 仿真验证

依据 Otsu-EWT 的降噪方法，进行仿真实验，仿真信号是由 5 Hz、20 Hz、100 Hz 和高斯白噪声组成，采样频率 1024 Hz。该信号包含一个正弦信号、一个调幅 - 调频和一个调幅信号，分解结果如图 7 所示：






图 7 复杂信号的 Otsu-EWT 分解

Figure 7 Otsu-EWT decomposition of complex signals

从上图可以看出，Otsu-EWT 对信号分解可以将仿真信号的各种存在形式划分开，第一个区间为正弦信号；第二个为调幅-调频的信号；第三个为调幅信号；Otsu-EWT 能够准确将各个信号进行区分，也验证了 Otsu-EWT 对信号分解的优越性和有效性。





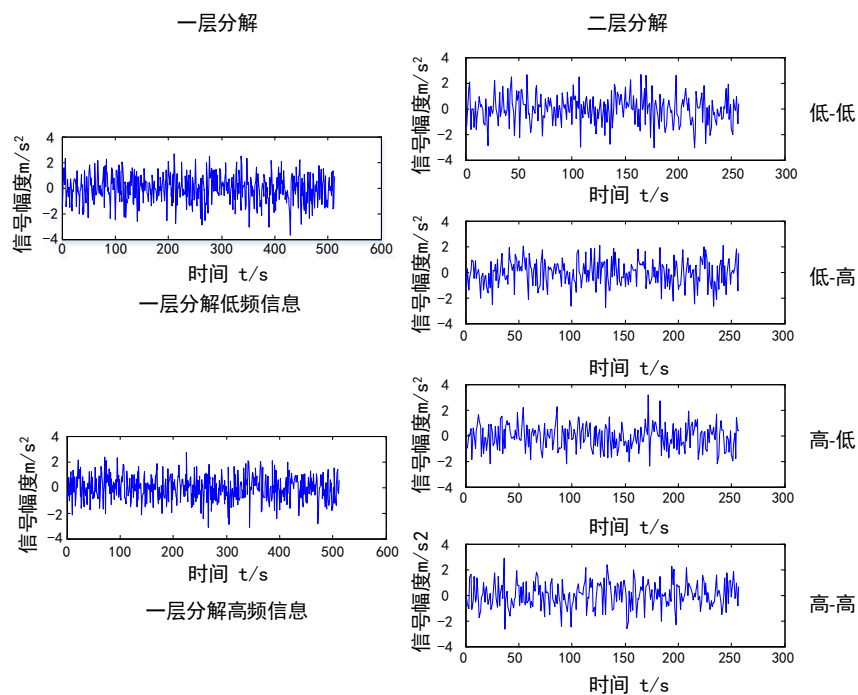
图 8 正弦信号改变后分解图

Figure 8 Decomposition diagram of sinusoidal signal after change


Otsu-EWT、CEEMD 和小波变换分解对比如图 9 所示



(a) Otsu-EWT 分解图



(b) 双层小波变换




(c) CEEMD 分解图

图 9 Otsu-EWT、小波变换和 CEEMD 对比


Figure 9 Otsu-EWT、wavelet transform and CEEMD

通过对比可以发现，Otsu-EWT 分解后的信号与小波变换、CEEMD 分解相比得到的分量更少，每个调幅-调频分量中仅含有一个主频成分，不同的分量之间不存在模态混叠现象，更不存在固定小波后再分解导致的窗固定问题，对同一个信号 Otsu-EWT 的分解速度要优于其他的信号分解方法。


通过波峰指标、峭度和均方根指标对轴承运行状态进行观察，对比如图 10 所示，脉冲指标、峰值指标、均方根指标在前期运行状态比较稳定，在第 26 天开始，指标数值明显增加，说明该指标能够较好地描述轴承发生异常的时间。



(a) 以波峰因素为指标的变化曲线图



(b) 以峭度为指标的变化曲线图



(c) 以均方根为指标的变化曲线图

图 10 不同指标的变化曲线图

Figure 10 Variation Curves of Different Indicators

## 5.2 实验验证

为了验证该方法的有效性,采用辛辛那提大学的公开数据进行验证。该试验台共有四个双列滚动轴承,实验的总天数 34 天,采样间隔十分钟一次,历时 34 天的实验过程,滚动轴承 3 在最后阶段发生了内圈磨损故障。

将 Otsu-EWT 应用到降噪过程,将降噪后的结果导入到基于进化神经网络预测模型当中进行预测,本文将传统的支持向量机、极限学习机和进化的神经网络进行预测精度和各个指标参数进行对比分别得到如图 11 所示预测效果。








图 11 各种数学模型预测数据对比

Figure 11 Various mathematical models predict data comparison

由表 1 可知:

(1) 相关度是指两个事物之间的相关性,表中用百分比显示(表中不是用百分比表示),基于进化的神经网络的线性相关度达到 94.36%(表中无此数据),相比传统的 ELM 和 SVM 的相关性更大,效果更好。

(2) 均方根值是检测值与理论值偏差的平方和检测次数比值的平方根,均方根值能够很好地体现测量的精密度,进化神经网络的均方误差低于前两者。

表 1 预测模型各指标对比

Table 1 Predictive model comparison of indicators

数学模型	均方误差	相关度
ELM	15.5832	58.12%
SVM	19.6070	60.10%
进化神经网络	0.0087	94.36%

## 6 结语

本文提出一种 Otsu-EWT 与进化神经网络相结合的故障预测方法,通过仿真与试验验证得到以下结论:

(1) Otsu-EWT 相比传统的信号分解,能够准确地划分信号的各个区间,克服了模式混叠,并且分解后的信号的调幅-调频分量仅对应一个频率,分解的准确性较高。

(2) 通过评价指标对各调幅-调频分量的筛选,可以得到相关性最大的一组,降噪效果比较明显。

(3) 进化神经网络和 SVM、ELM 相比,预测精度更高,均方根误差更小。

## 基金项目

国家自然科学基金项目资助(51575143)以及省自然科学基金项目资助(E2018046)。

## 参考文献

- [1] 彭宇, 刘大同. 数据驱动故障预测和健康管理综述 [J]. 仪器仪表学报, 2014, 35 (3): 481–495.
- [2] 王亚萍, 许迪, 葛江华, 等. 基于 SPWVD 时频图纹理特征的滚动轴承故障诊断 [J]. 振动、测试与诊断, 2017, 37 (1): 115–119.
- [3] 匡宇麒. 基于随机共振和 Otsu-EWT 的滚动轴承早期故障诊断方法 [D]. 哈尔滨理工大学, 2018.
- [4] Gilles J. Empirical Wavelet Transform [J]. IEEE Transactions on Signal Processing, 2013, 61 (61): 3999–4010.  
<https://doi.org/10.1109/TSP.2013.2265222>
- [5] 邓飞跃, 强亚文, 杨绍普, 等. 一种自适应频率窗经验小波变换的滚动轴承故障诊断方法 [J]. 西安交通大学学报, 2018, 52 (8): 22–29.
- [6] Luo Z J, Liu T, Yan S. Revised empirical wavelet transform based on auto-regressive power spectrum and its application to the mode decomposition of deployable structure [J]. Journal of Sound and Vibration, 2018, 431: 70–87.  
<https://doi.org/10.1016/j.jsv.2018.06.001>
- [7] 陈志新, 刘鑫, 卢成林, 等. 基于经验小波变换的复杂强噪声背景下弱故障检测方法 [J]. 农业工程学报, 2016, 32 (20): 202–208.
- [8] 何明慧. 基于进化算法的神经网络研究与优化 [D]. 安徽大学, 2018.
- [9] 李欣, 王晓燕. 基于 EtherCAT 和遗传 -BP 神经网络的等温锻造电液伺服系统优化研究 [J]. 机电工程, 2019 (5): 534–538.
- [10] 姜泽楠, 于大泳. 基于遗传算法和 BP 神经网络的 Stewart 平台正解研究 [J]. 中国水运 (下半月), 2019, 19 (7): 88–90.