

控制与决策

Control and Decision

基于径向基神经网络的新型齿轮故障诊断方法

薛萍, 郝鹏, 王宏民

引用本文:

薛萍, 郝鹏, 王宏民. 基于径向基神经网络的新型齿轮故障诊断方法[J]. *控制与决策*, 2022, 37(2): 409–416.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0836>

您可能感兴趣的其他文章

Articles you may be interested in

基于动态观测的随机离散事件系统故障诊断

Failure diagnosis of stochastic discrete event systems based on dynamic observations

控制与决策. 2022, 37(2): 417–423 <https://doi.org/10.13195/j.kzyjc.2020.1115>

基于鲸鱼算法优化LSSVM的滚动轴承故障诊断

Fault diagnosis method of rolling bearing based on LSSVM optimized by whale optimization algorithm

控制与决策. 2022, 37(1): 230–236 <https://doi.org/10.13195/j.kzyjc.2020.1147>

基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

标签Petri网的路径信息在故障诊断中的应用

Application of path information of labeled Petri nets in fault diagnosis

控制与决策. 2021, 36(2): 325–334 <https://doi.org/10.13195/j.kzyjc.2019.0698>

高超声速飞行器间歇故障改进自适应容错控制

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

基于径向基神经网络的新型齿轮故障诊断方法

薛萍[†], 郝鹏, 王宏民

(哈尔滨理工大学 自动化学院, 哈尔滨 150080)

摘要: 非平稳工况下的齿轮故障检测是一项非常困难的工作, 由于齿轮振动信号的复杂性, 导致故障特征提取和故障诊断困难. 针对这些问题, 基于径向基 (radial basis function, RBF) 神经网络, 提出一种在变速条件下齿轮的故障诊断方法 CIHDRFD. 首先利用自适应白噪声的完整集成经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN), 将原始振动信号分解为多个固有的模态函数 (intrinsic mode function, IMF), 并通过计算其信息熵 (information entropy, IE) 筛选出 IE 最小的 4 个 IMF 作为特征 IMF; 然后利用希尔伯特变换 (hilbert transform, HT) 处理特征 IMF 并求出 Hilbert 包络谱, 利用 Hilbert 包络谱构建故障特征向量; 最后利用改进的双 RBF 神经网络进行故障检测. 通过搭建齿轮故障检测平台验证 CIHDRFD 方法的有效性, 实验结果表明, CIHDRFD 方法适用于齿轮故障诊断, 在速度波动为 3% 的情况下, 诊断准确率和诊断时间分别为 98.21% 和 74.53 s.

关键词: 齿轮故障诊断; 自适应白噪声; 完整集成经验模态分析; 信息熵; 改进的双 RBF 神经网络

中图分类号: TP18

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0836

开放科学(资源服务)标识码(OSID):



引用格式: 薛萍, 郝鹏, 王宏民. 基于径向基神经网络的新型齿轮故障诊断方法 [J]. 控制与决策, 2022, 37(2): 409-416.

Novel gear fault diagnosis method based on RBF neural network

XUE Ping[†], HAO Peng, WANG Hong-min

(School of Automation, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: It is a very difficult work to detect gear fault under non-stationary condition. Due to the complexity of gear vibration signals, it is difficult to extract fault features and diagnose faults. In order to solve these problems, based on radial basis function (RBF) neural network, this paper proposes a gear fault diagnosis method, which is CIHDRFD. In the CIHDRFD method, complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) is used firstly to decompose the original vibration signal into multiple inherent modal functions (IMFs), and by calculating its information entropy (IE), the 4 IMFs with the smallest IE are selected as the characteristic IMF. Then, the Hilbert transform (HT) is used to process the feature IMF and the Hilbert envelope spectrum is obtained. The Hilbert envelope spectrum is used to construct the fault feature vector. Finally, the improved double RBF neural network is used for fault diagnosis. The effectiveness of the CIHDRFD method is verified by building a gear failure detection platform. Experimental results show that the CIHDRFD method is suitable for gear fault diagnosis. When the speed fluctuation is 3%, the diagnostic accuracy and diagnosis time of the CIHDRFD method are 98.21% and 74.53 s, respectively.

Keywords: gear fault diagnosis; adaptive noise; complete ensemble empirical mode decomposition; information entropy; improved double RBF neural network

0 引言

齿轮作为一种常用零件, 是机械动力传输中的重要组成部分, 并广泛应用于各个领域. 非平稳状态是旋转机械的运行状态, 齿轮作为旋转机械的重要组成部分, 其质量直接影响旋转机械的运行状态. 但是, 非

平稳工况下齿轮振动信号的复杂性给齿轮故障诊断带来较大困难.

齿轮故障诊断主要包括特征提取和状态识别两方面. 基于振动信号的故障诊断是最常用的技术之一^[1-4]. 在特征提取方面, 对于非平稳时间序列信

收稿日期: 2020-06-25; 录用日期: 2020-11-23.

基金项目: 先进制造智能化技术教育部重点实验室项目; 黑龙江省应用技术与开发计划项目 (GC13A412); 哈尔滨市科技创新人才项目 (2016RQXXJ055).

责任编辑: 胡庆雷.

[†]通讯作者. E-mail: xueping@hrbust.edu.cn.

号,具有时频两域多尺度解析能力的小波变换^[5-7]在非平稳信号分析中得到更为广泛的应用.但是小波变换本身存在一些不可避免的缺陷,如小波基函数的选择^[8]和降噪阈值的选择通常根据经验确定,具有较强的主观性,且存在能量泄露的问题.近年来,Huang等^[9]提出的经验模态分解(empirical mode decomposition, EMD)更适应于非线性信号的分析,但是容易受到模态混叠的影响.Wu等^[10]针对模态混叠的影响通过在初始信号中加入正态分布的白噪声辅助EMD算法,提出一种集成EMD(ensemble empirical mode decomposition, EEMD).Torres等^[11]在EEMD的基础上提出了自适应白噪声的完整集成经验模态分解CEEMDAN信号处理方法^[11],该方法在EEMD的基础上通过自适应加入白噪声,克服了EEMD在加入白噪声后分解失去完备性、产生重构误差的问题.因此,CEEMDAN方法在信号处理方面具有一定的优越性.信息熵是对信号或系统状态的不确定性程度定量描述的一种有效测度指标.信息熵理论通常与不同信号分析方法相结合,对不同的测试对象进行信号定量描述^[12].Hilbert变换在信号的时频分析方面具有良好的效果^[13-15].在状态识别方面,主要方法有神经网络和支持向量机(support vector machine, SVM)^[16-17]等.如Yang等^[18]将RBF网络结合优化的小波神经网络应用于齿轮箱故障诊断中;Zhang等^[19]将奇异值分解和RBF神经网络相结合进行齿轮的故障诊断.上述方法在齿轮故障诊断方面取得了较好的效果,但不适用于非平稳工况下齿轮的故障诊断.因此,有必要研究新的故障诊断模型.

齿轮故障诊断发展是一个渐进的过程,为了有效地进行故障诊断,揭示故障的发展演变过程,针对非平稳工况下齿轮故障检测困难的问题,本文将CEEMDAN、IE、HT和RBF神经网络引入故障诊断中,并深入研究齿轮故障诊断新模型.最后通过搭建齿轮故障检测平台验证CIHDRFD方法的有效性,实验结果表明,CIHDRFD方法适用于齿轮故障诊断,在速度波动为3%的情况下,诊断准确率和诊断时间分别为98.21%和74.53s.

1 故障诊断理论

1.1 故障诊断方法的选取

采集到的原始振动信号如图1所示.故障信号与干扰噪声信号混叠在一起,为了将故障信息从复杂的振动信号中分离出来,选用CEEMDAN方法对振动信号进行模态分解.其能分解出多个模态函数,有的包含故障信息,有的包含干扰信息.为了将包含故障

信息的模态函数选出,根据旋转机械故障信号的时频特性,引入了信息熵.利用信息熵选出包含故障信息的模态函数,为后续的故障诊断提供准确数据.然后将含有故障信息的模态函数经过Hilbert变换求出其Hilbert包络谱,得到清晰的故障特征频率作为故障诊断的特征依据.因此,将CEEMDAN、IE与HT相结合进行故障特征提取,能够有效地减少干扰噪声的影响,提取准确的故障信息.




图1 原始振动信号

基于提取的故障特征数据非线性特点,选用非线性逼近能力强、结构简单且训练快速的RBF神经网络进行故障诊断.此外,还有一些神经网络,如深度神经网络(deep neural networks, DNN)和卷积神经网络(convolutional neural networks, CNN),但由于DNN和CNN参数众多,网络结构搭建复杂,在构建模型时往往需要反复实验和人为经验以确定最佳模型,而且已构建的模型重用率不高,面对新的诊断问题往往需要重新构建模型,在一定程度上限制了在故障诊断领域的应用.本文基于故障信号的特征,将CEEMDAN、IE、HT与RBF神经网络相结合进行故障特征诊断,以提高故障诊断的准确性和实效性.

1.2 相关理论基础

1.2.1 CEEMDAN理论

CEEMDAN算法步骤如下.

step 1: 定义算子 $E_j(\cdot)$ 为利用EMD方法分解出的第 j 个模态分量, $\text{im}f'_j$ 为CEEMDAN分解出的 j 个模态分量, $x(t)$ 为待处理的原信号, $\omega(t)$ 为高斯白噪声. CEEMDAN对原信号按一定信噪比添加高斯白噪声而形成的加噪信号 $x(t) + \varepsilon_0 \omega_i(t)$ 经EMD连续分解 I 次试验,得到

$$\text{im}f'_1 = \frac{1}{I} \sum_{i=1}^I \text{im}f_{i1}(t). \quad (1)$$

step 2: 计算第1阶段 ($j = 1$) 的第1个余量,有

$$r_1(t) = x(t) - \text{im}f'_1(t). \quad (2)$$

step 3: 利用EMD法分解信号 $r_1(t) + \varepsilon_1 E_1(\omega_i(t))$ ($i = 1, 2, \dots, I$), 分解得到其第1个模态分量,接着定

义第2个模态为

$$\text{im}f'_2 = \frac{1}{I} \sum_{i=1}^I E_1(r_1(t) + \varepsilon_1 E_1(\omega_i(t))). \quad (3)$$

step 4: 定义 j 阶信号

$$r_j(t) = r_{j-1}(t) - \text{im}f'_j(t). \quad (4)$$

step 5: 继续利用 EMD 分解 j 阶信号 $r_j(t) + \varepsilon_i E_i(\omega_i(t)) (i = 1, 2, \dots, I)$, 同 step 3, 得到其第 1 个模态分量即可, 定义 CEEMDAN 的第 $j + 1$ 个模态为

$$\text{im}f'_{j+1}(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_j(t) + \varepsilon_j E_j(\omega_i(t))). \quad (5)$$

step 6: 将 j 加 1, 继续执行 step 4, 直至所获取的参与信号不能再被分解为止, 最后共有 J 个模态分量, 残余信号为

$$R(t) = r(t) - \sum_{j=1}^J \text{im}f'_j(t). \quad (6)$$

原始信号用 CEEMDAN 模态分量与余量表示为

$$x(t) = \sum_{j=1}^J \text{im}f'_j(t) + R(t). \quad (7)$$

1.2.2 信息熵理论

信息熵用以度量信息的不确定程度, 对系统的内在信息具有较强的刻画能力, 信息熵的大小与随机事件的概率有关, 越小概率发生的事件, 产生的信息量越多, 信息熵越大; 越大概率发生的事件, 信息熵越小. 信息熵越大表明事物所处的状态越稳定; 反之则表明该事物所处的状态越不稳定. 信息熵在故障诊断方面已经得到了应用, Qin 等^[20] 提出一种滚动轴承的故障诊断方法, 将信息熵应用于滚动轴承的故障诊断方法中, 取得了较好的效果. 信息熵计算如下:

$$H(x) = - \sum_{i=1}^n p(x_i) \log(p(x_i)), \quad (8)$$

其中 $p(x_i)$ 为随机事件 X_i 的概率.

1.2.3 RBF 神经网络模型

RBF 神经网络是一种单隐层结构, 其模型由输入层、隐含层和输出层组成. 从输入层空间到隐含层空间的变换是非线性的, 而从隐含层空间到输出层空间变换是线性的, 从而使线性不可分的问题变为线性可分. RBF 神经网络拓扑结构如图 2 所示. $x = \{x_1, x_2, \dots, x_n\}$ 为输入向量, $y = \{d_1, d_2, \dots, d_n\}$ 为输出向量. 输入向量与输出向量对应的映射关系为

$$y_i = \sum_{i=1}^h \omega_{ij} R_i(x_p - c_i). \quad (9)$$

其中: $j = 1, 2, \dots, n; \omega_{ij}$ 为隐含层到输出层的权值; h 为隐含层的神经元个数; $R_i(x_p - c_i)$ 为基函数,

即输入向量的高维映射关系. 本文选用高斯函数作为基函数, 即

$$R_i(x_p - c_i) = \exp\left(-\frac{1}{2\sigma_i^2} \|x_p - c_i\|^2\right). \quad (10)$$

其中: $i = 1, 2, \dots, h; x_p$ 为输入向量; c_i 为第 i 个高斯核函数的中心; h 为隐含层神经元个数; $\|x_p - c_i\|$ 为输入向量到 c_i 的欧氏距离; $R_i(x)$ 在 c_i 处服从高斯分布; σ_i 为第 i 个基函数中心的宽度, 采用最小二乘损失函数表示为

$$\sigma_i = \frac{1}{p} \sum_j^n \|d_j - y_j c_i\|^2, \quad i = 1, 2, \dots, h. \quad (11)$$




图 2 RBF 神经网络结构

2 基于 CEEMDAN、IE、HT 和改进的双 RBF 神经网络的故障诊断方法

2.1 CIHDFD 方法的思想

在 CIHDFD 方法中, 针对齿轮振动信号非线性非平稳的特点, 采用 CEEMDAN 方法对振动信号进行分解, 从而得到多个特征 IMF, 分解得到的特征 IMF 中包含很多非齿轮故障信号的特征 IMF, 在后期处理中会导致数据量增大, 并且容易导致误诊断. 但是, 信息熵的特性能够很好地反映故障信号的特征, 特征 IMF 分量中包含的故障信息越多, 其表现得越有序, 时频分布的聚集性越好, 信息熵的值越小. 相反, 得到的 IMF 分量中包含的齿轮故障特征信息越少, 其表现得越无序, 时频分布的聚集性越差. 本文依次计算出各个 IMF 分量的信息熵值^[21], 根据该值从小到大依次选择 IMF 作为特征 IMF, 经过反复实验确定, 图 3 为选择的特征 IMF 个数与诊断准确率的关系. 由图 3 可见, 选取 4 个 IMF 作为特征 IMF 故障诊断准确率较高. 因此, 综合考虑特征提取准确性和运算量, 利




图 3 选取的特征 IMF 个数与诊断准确率的关系

用信息熵最小的4个分量作为特征分量. 将选出的4个特征IMF分量利用Hilbert变换求出其Hilbert包络谱, 得到清晰的故障特征频率作为故障诊断的特征依据.

在故障诊断过程中, 诊断的准确率并没有达到理想的结果, 考虑到信息熵能够很好地反映出提取的特征数据包含故障信息量的多少, 若信息熵的值相差越大, 则反映出不同包络谱数据的差异越大. 因此, 采用信息熵相差较大的4个包络谱数据训练单RBF网络. 由于数据的复杂程度较高, 会导致故障诊断准确率下降. 为了减少数据的复杂程度, 将4组数据分别进行处理, 采用改进的4个RBF网络处理, 可以降低数据的复杂程度, 提高算法的复杂程度, 从而会增加算法的资源消耗, 执行效率变低. 因此, 综合考虑上述问题, 提出利用信息熵的值从小到大依次将提取到的4个故障特征的Hilbert包络谱数据分为两组处理, 并利用改进的双RBF神经网络进行故障诊断.

2.2 适用于齿轮故障诊断的改进的双RBF神经网络 齿轮故障诊断模型

图4为改进后的适用于齿轮故障诊断的双RBF神经网络拓扑结构. 本文将提取的4个特征IMF的Hilbert包络谱数据, 利用信息熵的值由小至大依次分为2组, 分别作为改进的双RBF网络的输入向量, 如图4所示, $x = \{x_1, x_2, \dots, x_n\}$, $m = \{u_1, u_2, \dots, u_n\}$.




图4 改进的双RBF神经网络结构

根据式(9)单个RBF模型中输入与输出的关系, 改进的双RBF神经网络对式(9)作出如下变换:

$$y_j = \sum_{i=1}^h \omega_{ij} R_i(x_p - c_i) + \sum_{i=1}^m \phi_{ij} E_j(u_p - b_i). \quad (12)$$

其中: $j = 1, 2, \dots, n$; $E_i(u_p - b_i)$ 为基函数, 即输入向量的高维映射关系. 如式(12)所示, 增加了一层输入与输出的关系, 从而使神经网络的模型符合齿轮的故

障特征的特性.

2.3 故障诊断模型

本文所提出的基于CEEMDAN、IE、HT和改进的双RBF神经网络的CIHDRFD方法模型如图5所示.

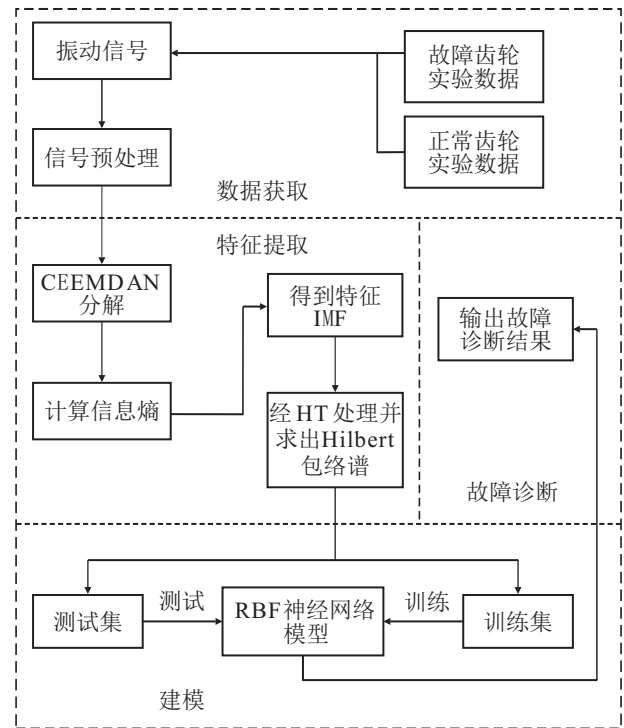


图5 故障诊断模型

故障诊断方法具体步骤如下.

- step 1: 利用加速度传感器获取齿轮的振动加速度信号;
- step 2: 利用CEEMDAN将振动加速度信号分解成一系列IMF;
- step 3: 计算每个IMF的信息熵(IE)并按照大小排列, 选取IE最小的4个IMF分量;
- step 4: 利用HT对选取的4个IMF分量进行处理, 并求得Hilbert包络谱, 从而得到故障特征;
- step 5: 每个特征IMF的Hilbert包络谱取1024个数据, 4个Hilbert包络谱数据按照特征IMF的IE大小分为2个一组, 每组数据头尾相连, 这样每组便是2048个数据, 构成2个一维的特征向量, 这些特征向量构成故障特征的样本数据集;
- step 6: RBF神经网络的输出层设计, 需要分析故障类型数目作为RBF神经网络的输出个数, 如果待识别的故障类型有j个, 则输出个数为j个;
- step 7: 输入训练特征样本对RBF神经网络进行训练, 训练后得到齿轮故障诊断模型, 实现故障诊断;
- step 8: 使用测试样本验证CIHDRFD方法的有效性, 通过诊断结果, 分析验证该方法的有效性和快速性.

3 CIHDRFD方法的验证与分析

3.1 实验环境与设备

搭建如图6、图7所示的齿轮实验平台,选择振动数据验证CIHDRFD方法.以1450r/min的平均速度获得振动数据,速度波动设置为3%,速度波动如图8所示.采样频率设置为5120Hz,采样点数为2048个.选取7种类型的数据作为验证数据,分别为正常、齿面磨损和裂纹,其中正常为1种类型,齿面磨损与裂纹分别选取3种不同等级的数据类型,为轻度、中度和重度,共7种类型.实验齿轮分类情况如表1所示.




图6 实验平台结构



图7 实验平台结构实物图




图8 速度变化

表1 实验齿轮分类情况

齿轮分类	磨损状况/mm	齿轮分类	裂纹情况/mm
正常	无故障	轻度裂纹	裂纹深度0.35
轻度磨损	公法线缩短0.05,基本无点蚀	中度裂纹	裂纹深度0.68
中度磨损	公法线缩短<0.1,部分齿点蚀	重度裂纹	裂纹深度1.23
重度磨损	公法线缩短0.1~0.2,点蚀严重		

3.2 齿轮故障特征提取

图9为中度磨损的齿轮CEEMDAN分解图.利用CEEMDAN将原始振动信号分解为不同的IMF分量,并计算分解后的各个IMF分量的IE,根据IE值的大小选取用于齿轮故障诊断的特征分量.各个IMF的IE值如表2所示.

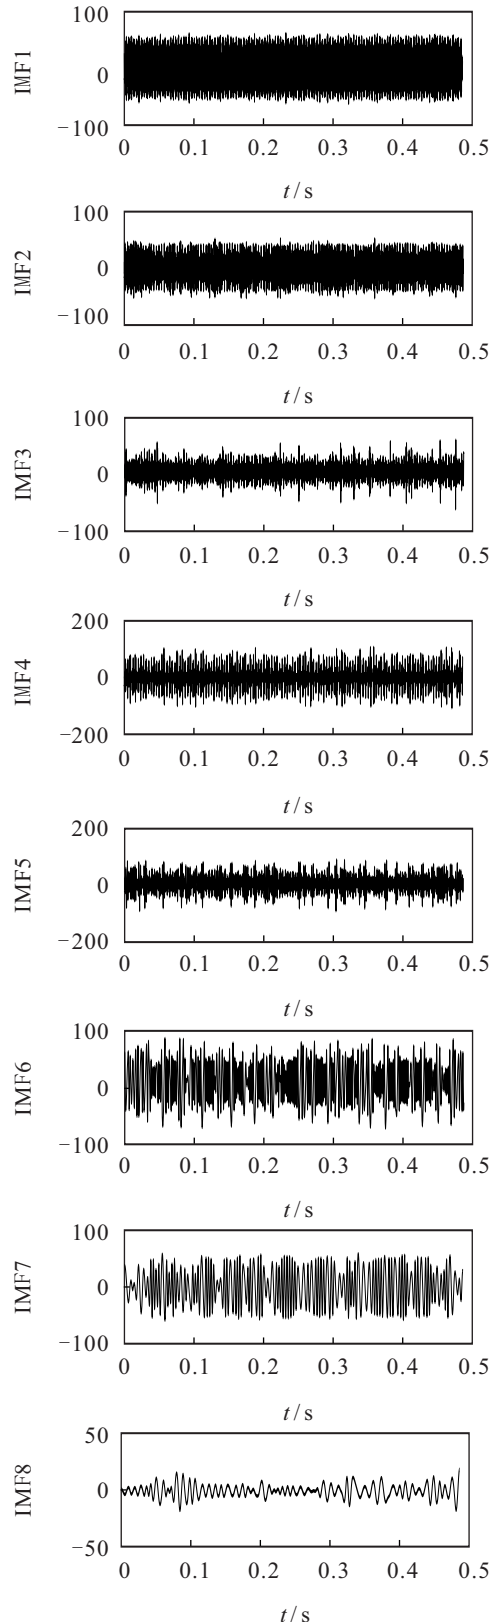


图9 振动信号(中度磨损)CEEMDAN分解图

表2 振动信号(中度磨损)各个IMF分量的IE值

模态分量	IE	模态分量	IE
IMF1	1.420 4	IMF5	2.496 5
IMF2	1.954 3	IMF6	2.616 5
IMF3	1.659 2	IMF7	2.851 1
IMF4	2.310 6	IMF8	2.772 4




图10 正常齿轮的Hilbert 包络数据




图11 齿轮轻度磨损的Hilbert 包络数据

通过计算各个IMF的IE值,得到用于获取齿轮故障特征的IMF.由表2可见,IE最小的4个IMF由小至大依次为IMF1、IMF3、IMF2和IMF4,将这4个IMF作为特征IMF,并通过HT处理得到其Hilbert包络谱.每个特征IMF的Hilbert包络谱取1024个数据,4个Hilbert包络谱数据按照IE的大小分为2个一组,每组数据头尾相连,这样每组便是2048个数据,构成2个一维的特征向量.这些特征向量构成故障特征的样本数据集.按照IE从小到大排列提取的部分不同故障类型的Hilbert包络谱数据如图10~图12所示.




图12 齿轮中度磨损的Hilbert 包络数据

3.3 诊断结果对比分析

实验选取7种不同类型的数据,每种80组,共560组数据作为样本数据集,随机选择其中20%的数据作为测试样本,其余为训练样本.实验设置的输出为2个,分别代表两种不同的故障类型.输出的故障代码和故障类型如表3所示.

表3 故障类型与对应代码

故障代码	故障类型	故障代码	故障类型
0	0 正常	0	1 轻度裂纹
1	0 轻度磨损	0	1.5 中度裂纹
1.5	0 中度磨损	0	2 重度裂纹
2	0 重度磨损		

为了验证所提出齿轮故障诊断 CIHDRFD 方法中使用改进的双 RBF 神经网络的有效性, 在一定的特征提取方法条件下, 同时与以下几种方法进行对比实验. 方法 1: 在获得 4 个特征包络谱的基础上使用未改进的 RBF 神经网络进行故障诊断, 称为 CIHRFD1 方法; 方法 2: 将获得的 4 个特征包络谱采用改进的 4 个 RBF 网络进行处理, 称为 CIHRFD2 方法; 方法 3: 在获得 4 个特征包络谱的基础上使用 SVM 进行故障诊断, 称为 CIHSFD 方法; 方法 4: 在获得 4 个特征包络谱的基础上使用 CNN 网络进行故障诊断, 称为 CIHCFD 方法. 经过大量实验得到的故障诊断准确率和诊断时间如表 4 所示.

表 4 不同方法的诊断准确率和诊断时间

故障诊断方法	诊断准确率/%	诊断时间/s
CIHDRFD	98.21	74.53
CIHRFD1	92.78	105.98
CIHRFD2	97.45	95.34
CIHCFD	87.35	180.93
CIHSFD	60.36	250.77

为了直观地观察对比实验情况, 本文选取 CIHDRFD 与 CIHSFD 两种方法的测试结果作图分析. 选取正常类型与不同程度磨损故障类型每种 10 组数据进行对比分析, 结果如图 13 和图 14 所示.




图 13 CIHDRFD 方法测试结果




图 14 CIHSFD 方法测试结果

由图 13 可见, 基于改进的双 RBF 神经网络的 CIHDRFD 方法测试结果呈梯形增加, 表示 CIHDRFD 方法可以显著区分正常样本与不同程度的故障样本. 由图 14 可见, 基于 SVM 的 CIHSFD 方法测试结果在一定范围内波动较大, 并且存在错误诊断, 诊断效果较差, 验证了 CIHDRFD 方法在故障诊断中具有很

好的效果.

为进一步验证 CIHDRFD 采用 CEEMDAN 方法进行故障特征提取的有效性, 在与 CIHDRFD 方法相同的模型条件下, 特征提取方法分别采用 CEEMDAN、EMD 和 EEMD 进行对比实验. 将采用 EMD 的方法称为 EIHDRFD, 采用 EEMD 的方法称为 EIHDRFD1. 经过大量实验得到的诊断准确率和诊断时间如表 5 所示.

表 5 采用不同特征提取方法的诊断准确率和诊断时间

故障诊断方法	诊断准确率/%	诊断时间/s
CIHDRFD	98.21	74.53
EIHDRFD	72.45	78.32
EIHDRFD1	80.23	73.63

本文基于采用双 RBF 网络进行故障诊断, 分别与 CIHCFD、CIHSFD、CIHRFD1 和 CIHRFD2 四种方法进行对比实验, 实验结果如表 4 所示. 通过实验结果可知, CIHRFD1 方法诊断准确率高, 验证了选用 RBF 网络在故障诊断中效果较好. 通过分析 CIHDRFD、CIHRFD1 和 CIHRFD2 方法的结果可知, CIHDRFD 方法诊断准确率和诊断时间均优于 CIHRFD1 方法和 CIHRFD2 方法, 因此利用改进的双 RBF 神经网络进行故障诊断, 有效地提高了网络的收敛速度和逼近能力, 进一步提高了故障诊断的准确率, 验证了在 CIHDRFD 方法中采用改进的双 RBF 神经网络进行故障诊断效果较好.

本文同时基于 CEEMDAN 方法进行故障特征提取, 在相同的模型条件下与 EIHDRFD 方法和 EIHDRFD1 方法进行对比分析, 由表 5 结果可以看出, CIHDRFD 方法的诊断准确率均高于 EIHDRFD 方法和 EIHDRFD1 方法, 验证了基于 CEEMDAN 方法进行故障特征提取的效果较好. 基于上述分析, 所提出的 CIHDRFD 方法具有优越性.

4 结论

在变速度条件下, 本文提出了一种基于自适应白噪声的完整集成经验模态分解 (CEEMDAN) 结合信息熵 (IE)、希尔伯特变换 (HT) 和改进的双 RBF 神经网络的齿轮故障诊断方法 CIHDRFD. 实际振动数据验证了所提出方法的有效性, CIHDRFD 方法的诊断准确率为 98.21%, 诊断时间为 74.53 s. 实验结果表明, 基于改进的双 RBF 神经网络的 CIHDRFD 方法可以建立齿轮故障诊断模型, 并且具有诊断精度高、诊断速度快的优点. 在今后的工作中, 为解决实际的工程问题, 将会设计一个全新的实验平台以采集更多的数据, 并不断地研究与改进齿轮的故障诊断方法.

参考文献(References)

- [1] Pan H Y, Yang Y, Li X, et al. Symplectic geometry mode decomposition and its application to rotating machinery compound fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2019, 114: 189-211.
- [2] He S L, Chen J L, Zhou Z T, et al. Multifractal entropy based adaptive multiwavelet construction and its application for mechanical compound-fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2016, 76/77: 742-758.
- [3] Wang T Y, Chu F L, Han Q K, et al. Compound faults detection in gearbox via meshing resonance and spectral kurtosis methods[J]. *Journal of Sound and Vibration*, 2017, 392: 367-381.
- [4] Taplak H, Erkaya S, Uzmay İ. Experimental analysis on fault detection for a direct coupled rotor-bearing system[J]. *Measurement*, 2013, 46(1): 336-344.
- [5] Aharamuthu K, Ayyasamy E P. Application of discrete wavelet transform and Zhao-Atlas-Marks transforms in non stationary gear fault diagnosis[J]. *Journal of Mechanical Science and Technology*, 2013, 27(3): 641-647.
- [6] Zhou J M, Wang F L, Zhang C C, et al. Evaluation of rolling bearing performance degradation using wavelet packet energy entropy and RBF neural network[J]. *Symmetry*, 2019, 11(8): 1064.
- [7] Hsueh Y M, Ittangihal V R, Wu W B, et al. Fault diagnosis system for induction motors by CNN using empirical wavelet transform[J]. *Symmetry*, 2019, 11(10): 1212.
- [8] 何正嘉, 訾艳阳, 高强, 等. 机械动态分析与诊断中小波基函数的选择[C]. 全国振动(诊断、模态、噪声与结构力学)工程与应用学术会议. 上海: 上海高教电子音像出版社, 2002: 144-148.
(He Z J, Zi Y Y, Gao Q, et al. Selection of wavelet basis function in mechanical dynamic analysis and diagnosis[C]. *The National Conference on Vibration (Diagnosis, Modal, Noise and Structural Mechanics) Engineering and Application*. Shanghai: Shanghai Higher Educational Electronic Audio & Visual Publishing House, 2002: 144-148.)
- [9] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995.
- [10] Wu Z H, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1-41.
- [11] Torres M E, Colominas M A, Schlotthauer G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Piscataway: IEEE, 2011: 4144-4147.
- [12] 潘瑞林, 李园沁, 张洪亮, 等. 基于 α 信息熵的模糊粗糙属性约简方法[J]. *控制与决策*, 2017, 32(2): 340-348.
(Pan R L, Li Y Q, Zhang H L, et al. Fuzzy-rough attribute reduction algorithm based on α information entropy[J]. *Control and Decision*, 2017, 32(2): 340-348.)
- [13] Wang H J, Ji Y J. A revised Hilbert-Huang transform and its application to fault diagnosis in a rotor system[J]. *Sensors*, 2018, 18(12): 4329.
- [14] Chen H G, Chen P, Chen W H, et al. Wind turbine gearbox fault diagnosis based on improved EEMD and Hilbert square demodulation[J]. *Applied Sciences*, 2017, 7(2): 128.
- [15] 孙会文, 伏云发, 熊馨, 等. 基于HHT运动想象脑电模式识别研究[J]. *自动化学报*, 2015, 41(9): 1686-1692.
(Sun H W, Fu Y F, Xiong X, et al. Identification of EEG induced by motor imagery based on Hilbert-Huang transform[J]. *Acta Automatica Sinica*, 2015, 41(9): 1686-1692.)
- [16] Cui L H, Liu Y, Zhou D H. Fault diagnosis of the planetary gearbox based on ssDAG-SVM[J]. *IFAC-PapersOnLine*, 2018, 51(24): 263-267.
- [17] 黄海松, 魏建安, 康佩栋. 基于不平衡数据样本特性的新型过采样SVM分类算法[J]. *控制与决策*, 2018, 33(9): 1549-1558.
(Huang H S, Wei J A, Kang P D. New over-sampling SVM classification algorithm based on unbalanced data sample characteristics[J]. *Control and Decision*, 2018, 33(9): 1549-1558.)
- [18] Yang L, Chen H X. Fault diagnosis of gearbox based on RBF-PF and particle swarm optimization wavelet neural network[J]. *Neural Computing and Applications*, 2019, 31(9): 4463-4478.
- [19] Zhang Q, Zhao W, Xiao S G. Fault diagnosis of gear based on singular value decomposition and RBF neural network[C]. *The 2nd International Conference on Frontiers of Sensors. Technologies: ICFST*, 2017: 470-474.
- [20] Qin W L, Zhang W J, Lu C. Rolling bearing fault diagnosis: A data-based method using EEMD, information entropy and one-versus-one SVM[C]. *The 12th World Congress on Intelligent Control and Automation: WCICA*. Guilin, 2016: 1016-1020.
- [21] 朱瑜, 王殿, 王海洋. 基于EMD和信息熵的滚动轴承故障诊断[J]. *轴承*, 2012(6): 50-53.
(Zhu Y, Wang D, Wang H Y. Fault diagnosis of rolling bearings based on EMD and information entropy[J]. *Bearing*, 2012(6): 50-53.)

作者简介

薛萍(1969—), 女, 教授, 博士, 从事光电检测与电子信息处理技术等研究, E-mail: xueping@hrbust.edu.cn;

郝鹏(1993—), 男, 硕士生, 从事智能信息处理技术的研究, E-mail: 1479171205@qq.com;

王宏民(1962—), 男, 教授, 博士, 从事电子信息与嵌入式检测技术等研究, E-mail: 13904810908@163.com.