

基于 EEMD 能量矩和改进量子粒子群神经网络的滚动轴承故障诊断

闵文君¹, 李国平^{1*}, 韩同鹏², 项四通¹, 赖文锋¹

(1. 宁波大学 机械工程与力学学院, 浙江 宁波 315211; 2. 华夏幸福产业新城(杭州)有限公司, 浙江 杭州 310000)

摘要: 针对滚动轴承故障振动信号的非线性和周期性冲击特征, 提出一种基于集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)能量矩和改进量子粒子群神经网络的特征提取方法. 基于小波去噪对滚动轴承原始信号进行预处理, 对重构的故障信号进行 EEMD 并得到多个本征模态函数分量. 利用能量矩方法计算出所需分量的能量矩并归一化, 将归一化后的能量矩特征参数作为量子粒子群 BP 神经网络的参数输入, 根据加速度传感器信号实现滚动轴承故障诊断. 分别在不同转速(载荷)下采集驱动端轴承的振动信号, 获取 200 个训练样本和 80 个测试样本, 并建立故障诊断模型. 基于文中模型对实际滚动轴承数据进行诊断, 实验结果表明, 不同转速(载荷)下测试的 80 个样本故障诊断准确率达到 100%.

关键词: 滚动轴承; 故障诊断; 集合经验模态分解; 能量矩; 改进量子粒子群

中图分类号: TH133.3

文献标志码: A

文章编号: 1001-5132(2020)03-0033-07

在现代工业生产制造环节中, 滚动轴承作为旋转机械设备常用的部件, 广泛应用于各种旋转机械. 轴承主要包含内圈、外圈、滚动元件和保持架. 任何一个上述组件的故障都可能导致整个系统的性能降低, 乃至出现致命的机器故障或灾难性事故. 为了预防滚动轴承在工作时发生故障, 许多学者对滚动轴承的状态监测和故障诊断进行了持续研究, 同时这也一直是机械设备诊断的热点和难点. 因此, 自动和及时地识别轴承操作条件对于减少意外停机时间和经济损失变得越来越重要. 其中智能诊断是轴承故障检测技术发展的新方向, 它可以有效地分析海量采集数据并自动提供可靠的诊断结果. 在不同的智能诊断方法中, 人工神经网络和支持向量机在过去几十年中应用最广泛^[1-2].

振动信号提供了关于旋转机械中轴承工作状况的丰富信息. 对从振动信号中提取的不同特征进行分析, 已经在旋转机械的故障检测或故障诊断方面起到了非常有效的作用^[3-4]. 到目前为止,

已有许多信号处理方法来分析所收集的特征振动信号, 它们可以归纳为 3 种类型^[5]: 时域、频域和时频域. 然而, 上述方法仅能从振动信号中提取一部分有用信息, 并且会导致其他域的信息丢失. 因此, 越来越多的研究人员引入了用于机械特征提取的时频处理工具, Huang 等^[6]提出了经验模式分解(Empirical Mode Decomposition, EMD), 此方法对于振动信号处理具有自适应的特点. 因此, 很多学者利用 EMD 进行振动信号故障诊断^[7-9]. 但 EMD 存在模态混叠、虚假模态和端点效应等不足之处^[10]. 为了抑制模态混叠问题, Wu 等^[11]提出了 EEMD (Ensemble EMD), 它有效地抑制了模态混叠现象. 张立国等^[12]提出了一种基于 EEMD 和奇异值分解的模糊 C 均值聚类相结合的轴承故障诊断方法. 针对信噪比低时 EEMD 方法去噪功能通常不理想的问题, Li 等^[13]提出了一种结合 EEMD 和改进频带熵的滚动轴承故障特征提取方法, 通过设计一种带通滤波器对本征模态函数(Intrinsic

收稿日期: 2019-12-05.

宁波大学学报(理工版)网址: <http://journal.lg.nbu.edu.cn/>

基金项目: 国家自然科学基金(51705262).

第一作者: 闵文君(1995-), 男, 安徽宣城人, 在读硕士研究生, 主要研究方向: 机械振动控制、信号处理. E-mail: minwenjun51@163.com

*通信作者: 李国平(1967-), 男, 湖北武穴人, 教授, 主要研究方向: 精密加工、机械振动控制. E-mail: liguoping@nbu.edu.cn

Mode Function, IMF)进行带通滤波,对滤波后的信号进行包络功率谱分析,提取故障特征频率,实现对轴承的故障诊断.

针对 EEMD 方法只考虑噪声幅值对分解结果的影响,而且添加的白噪声不能完全中和的问题,程军圣等^[14]提出一种改进的 EEMD 方法.通过仿真信号和实测信号分析,结果表明该改进方法在抑制模态混淆和故障诊断方面较原始方法有一定优势.彭畅等^[15]利用 EEMD、度量因子和快速峭度图的诊断方法,将原始信号进行滤波处理,将重构信号进行包络分析,并将包络谱与轴承故障特征频率进行比较,进一步完成故障诊断.

在智能诊断领域中,李恒等^[16]提出了基于短时傅里叶变换和卷积神经网络的故障诊断方法,从而实现了端到端的故障模式识别.于婷婷^[17]通过对滚动轴承正常工况和故障状态下的振动信号分析处理,选取分析处理后的部分特征参数作为神经网络的输入,设计了一种 BP 神经网络,用来完成对滚动轴承故障信号的提取. Nguyen 等^[18]提出了一种由自动编码器和 softmax 分类器组成的深度学习网络,用于识别各种多度轴承故障.自动编码器执行无监督特征自学习,以生成用于训练 softmax 分类器的最终有效特征向量并完成故障诊断. Yan 等^[19]提出了一种基于优化分类算法与多域特性的故障诊断方法,从多域方面(例如时域、频域和时频域)提取故障特征信息,采用基于粒子群优化的支持向量机分类模型实现轴承多故障识别.

以上研究对故障诊断都有一定成效,但也存在一些问题,例如在时频分析中存在交叉项干扰,故障特征提取仍存在端点效应和模态混叠现象.在处理大规模故障数据时,可能会占用计算机硬件内存,影响计算效率.基于此,本文将 EEMD 能量矩方法和改进量子粒子群 BP 神经网络结合起来,对滚动轴承工作信号进行分析与故障诊断.首先对采集到的轴承噪声信号进行小波去噪,再对去噪后的信号进行 EEMD,计算各 IMF 能量矩作为模型训练和测试的特征参数输入,对滚动轴承 4 种不同状况下的振动信号进行故障分类识别.

1 EEMD 方法

滚动轴承振动信号中的噪声、EMD 严重的端

点效应和模态混叠现象严重影响故障诊断的准确性,而 EEMD 是一种新的白噪声辅助数据的分析方法,它可以抑制 EMD 在工程应用中的某些模态混叠,并解决阈值和小波基函数选择问题.

如图 1 所示, EEMD 算法的步骤如下:

(1)针对原始信号 $x_0(t)$, 加入 m 组白噪声序列,生成新的复合信号 $x_i(t)$ ($i=1, \dots, m$).

(2)对于新生成的复合信号 $x_i(t)$ 进行 EMD, 得到 n 个 IMF 分量 $c_{ij}(t)$ ($j=1, \dots, n$) 和剩余信号 $R_i(t)$.

重复步骤(1)~(2) n 次, 得到信号 $x_i(t)$ 的 n 个 IMF 分量, 循环 n 次后, 信号 $x_i(t)$ 可表示为

$$x_i(t) = \sum_{j=1}^n c_{ij}(t) + R_m(t). \quad (1)$$

(3)计算分解后 m 组 IMF 分量相应的均值 $\{C_1, C_2, \dots, C_n\}$ 和 m 组余量的均值 R , 取 IMF 的均值作为最终的结果.

对原始信号 $x_0(t)$ 经过 EEMD 后得到的 n 个 IMF 分量为:

$$C_j = \frac{1}{m} \sum_{i=1}^m c_{ij}, \quad j=1, 2, \dots, n, \quad (2)$$

$$R = \frac{1}{m} \sum_{i=1}^m R_m. \quad (3)$$




图 1 EEMD 算法流程

2 IMF 能量矩

基于滚动轴承故障振动信号的非稳定性和非线性,采用 EEMD 方法对原始信号进行分解,获得一系列 IMF 分量,对于 IMF 特征提取,很多学者提出了近似熵、样本熵以及能量熵等其他基于时间序列提取特征向量的方法,但考虑到滚动轴承信号存在周期性的冲击性特征,本文提出一种 IMF 能量矩提取特征的方法.该方法能够有效地描述信

号的基本特征, 相比较其他方法, 具有效率高、速度快等优势.

计算 IMF 能量矩的步骤为:

(1) 对传感器采集的信号进行小波包消噪预处理.

(2) 利用 EEMD 方法分解去噪后的振动信号, 获得多个本征模态函数分量 $C_i (i=1,2,\dots,9)$.

(3) 计算能量矩, 连续信号和离散信号的计算式分别为:

$$E_i = \int |C_i(t)|^2 dt, \quad (4)$$

$$E_i = \sum_{k=1}^n (k \cdot \Delta t) |C_i(k \cdot \Delta t)|^2, \quad (5)$$

式中: k 为采样点; n 为总采样点数; Δt 为采样周期.

(4) 构造特征向量 T .

$$T = [E_1, E_2, \dots, E_n], \quad (6)$$

当 IMF 能量矩较大时, 归一化后得到特征向量

$$T' = \left[\frac{E_1}{E}, \frac{E_2}{E}, \dots, \frac{E_n}{E} \right], \quad (7)$$

$$\text{其中 } E = \left(\sum_{i=1}^n |E_i|^2 \right)^{1/2}.$$

3 改进量子粒子群神经网络

3.1 改进量子粒子群算法

为了防止量子粒子群陷入局部最优解, 引入收缩-扩张系数 α 调节量子粒子群优化(QPSO)算法的收敛过程, α 的参数控制对 QPSO 算法的计算性能有很大影响, 根据粒子群算法的动态惯性权重思想, 提出如下 α 计算式以实现 QPSO 自适应:

$$\alpha = (\alpha_{\max} - \alpha_{\min})(i_{\max} - i) / i_{\max} + \alpha_{\min}, \quad (8)$$

式中取 $\alpha_{\max} = 1.0$, $\alpha_{\min} = 0.5$.

3.2 量子粒子群 BP 神经网络方法

量子粒子群 BP 神经网络能够克服陷入局部最优, 且学习速度快, 改进后具有动态自适应性. 量子粒子群 BP 神经网络的设计如下:

输入层节点数 $g=9$, 将归一化的能量矩特征向量对应输入的 9 组参数. 输出层节点数 $f=4$, 分别对应滚动体故障、外圈故障、内圈故障和正常运行 4 种滚动轴承状态参数. 依据经验公式

$$M = \sqrt{g + f} + \lambda, \quad \lambda \in [1, 10], \quad (9)$$

确定隐含层神经元个数 $M=14$.

根据 BP 神经网络结构定义来构建量子粒子群

空间, 将神经网络权值和阈值进行粒子化, 其空间维数 D 可由经验公式 $D=g \times h + h \times f + h + f$ 确定, 其中 h 为隐含层节点数. 经过 QPSO 算法的不断搜索和迭代, 寻找到粒子最优位置向量, 取最优位置数值为 BP 神经网络权值和阈值. 改进的量子粒子群能够有效地避免局部收敛, 具有更优的全局搜索能力. 改进量子粒子群算法的流程如图 2 所示.




图2 改进量子粒子群算法的流程

改进量子粒子群 BP 神经网络算法实现如下:

(1) 对种群中所有粒子、算法相关基本参数进行初始化.

(2) 计算粒子的适应度, 根据位移方程计算粒子位置.

(3) 计算个体最优位置平均点, 更新种群中各个粒子的个体最优位置和种群全局最优位置.

(4) 迭代寻优, 判断当前进化代数是否达到终止条件.

(5) 重复执行(2)~(4), 直至达到最大进化代数.

(6) BP 神经网络的权值和阈值根据粒子群全局最优解计算得到.

采用均方根误差作为 QPSO-BP 神经网络算法的适应度函数, 定义为

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{\theta=1}^L [z^*(\theta) - z(\theta)]^2}{L}}, \quad (10)$$

式中: E_{RMS} 为均方根误差, 代表预测数据与真实数据间的偏离程度; L 为训练样本数量; $z(\theta)$ 和 $z^*(\theta)$ 分别表示真实数据和预测数据.

4 IMF 能量矩和改进量子粒子群 BP 神经网络的结合

图 3 为基于 IMF 能量矩和改进量子粒子群神经网络相结合的滚动轴承故障诊断框图. 滚动轴承故障诊断主要步骤为:

(1) 利用加速度传感器采集的原始振动信号进行小波包消噪信号预处理, 然后利用 EEMD 方法对消噪后的信号进行分解, 分解得到的 IMF 分量取前 9 组. 利用公式(5)计算出各个 IMF 分量的能量矩.

(2) 将 IMF 能量矩归一化处理构造特征向量, 包括训练样本和测试样本, 用于模型训练和测试.

(3) 构造特征向量作为改进量子粒子群 BP 神经网络的输入, 本文模型的输入层节点数为 9, 其中归一化的能量矩特征向量对应输入的 9 组参数. 输出层节点数为 4, 对应滚动轴承的 4 种不同运行状态. 根据经验公式确定隐含层神经元为 14 个.

(4) 利用量子粒子群 BP 神经网络, 将训练样本作为输入, 不断地进行样本训练, 最终构建滚动轴承故障诊断模型, 最后利用测试样本进行模型准确性检测, 模型的输出用来判断滚动轴承的实际工况.




图 3 滚动轴承故障诊断框图

5 实验验证

为验证本文所提出的 QPSO-BP 算法对实际机械设备故障诊断的有效性, 将美国凯斯西储大学

轴承振动公开数据库^[20]作为实验数据集进行实验验证. 该数据集是用于测试振动信号故障诊断算法的开放数据集. 实验台设备如图 4 所示, 实验台由 1491.4 W 三相感应电动机和测功机组成, 其中电动机用于产生驱动力, 测功机用于产生额定负载. 轴承型号为 6205-2RS JEM SKF, 球直径为 7.94 mm, 滚动体数量为 9. 将采样频率为 12 kHz 的加速度传感器分别安装在电动机的驱动端和风扇端, 用于采集故障轴承的振动信号. 使用电火花加工技术分别在轴承的内圈、外圈和滚动体上人为制造尺寸为 0.1778 mm 的单点缺陷. 采集不同负载下的振动数据用于实验分析.




图 4 轴承故障信号采集实验设备

图 5 为实验设备采集的滚动轴承原始振动信号, 包括正常工况、滚动体故障、外圈故障和内圈故障.




图 5 滚动轴承在不同状态下的原始振动信号

利用 EEMD 方法得到 9 组有效 IMF 分量, 计

算出能量矩并归一化后的 4 种不同工况下的特征向量(表 1).

表 1 基于集合经验模态分解和能量矩的归一化特征向量

向量	不同故障类型的分量值			
分量	(a)正常工况	(b)滚动体故障	(c)外圈故障	(d)内圈故障
E_1	0.589 049	0.887 080	0.958 052	0.753 672
E_2	0.145 719	0.046 137	0.026 179	0.163 460
E_3	0.076 620	0.048 205	0.008 351	0.064 574
E_4	0.116 554	0.009 072	0.002 847	0.011 975
E_5	0.036 154	0.008 238	0.003 750	0.004 236
E_6	0.030 278	0.000 752	0.000 520	0.000 948
E_7	0.004 075	0.000 225	0.000 186	0.000 560
E_8	0.001 350	0.000 030	0.000 042	0.000 286
E_9	0.000 201	0.000 262	0.000 073	0.000 290

表 2 为滚动轴承故障诊断样本信息. 其中 4 种状态下训练样本各 50 组, 测试样本各 20 组, 分别用于模型的训练和测试.

表 2 滚动轴承故障诊断样本信息			
轴承状态	训练样本数	测试样本数	类别标签
正常状态	50	20	(1,0,0,0)
滚动体故障	50	20	(0,1,0,0)
外圈故障	50	20	(0,0,1,0)
内圈故障	50	20	(0,0,0,1)

按 EEMD 方法分解正常状态原始信号如图 6 所示.




图 6 滚动轴承正常状态下原始信号 EEMD 分解

图 7 为不同模型下故障诊断的正确率比较, 纵坐标故障编号 a、b、c、d 分别代表程序判断滚动

轴承状态为正常、滚动体故障、外圈故障、内圈故障.




图 7 不同模型下故障诊断正确率比较

图 7(a)为未优化的 BP 神经网络, 在 80 个样本中存在 5 个误判, 分别将正常工况误判为滚动体故障, 外圈故障误判为滚动体故障, 诊断准确率为 93.75%。图 7(b)为本文所用模型——改进的量子粒子群 BP 神经网络(QPSO-BP), 在 80 个样本中, 故障诊断准确率达到 100%。图 7(c)和图 7(d)分别为粒子群 BP 神经网络和遗传算法 BP 神经网络, 两者故障诊断率分别为 98.75%和 97.5%。

相较于其他 3 种模型, 本文所用模型具有更高的故障诊断精度, 在 80 个测试样本中均达到 100%, 能够准确地对滚动轴承的运行状态进行诊断。

为了进一步验证 QPSO-BP 算法的准确性, 将 $1\,772\text{ r}\cdot\text{min}^{-1}$ (载荷 1 hp)以及 $1\,750\text{ r}\cdot\text{min}^{-1}$ (载荷 2 hp)两种不同工况下的振动数据作为样本, 输入到 QPSO-BP 神经网络进行训练, 分析神经网络的输出结果, 并与其他几种典型神经网络的结果进行对比。从表 3 可以看出, 在 1 hp 和 2 hp 下, QPSO-BP 能够准确识别故障模式, 准确率达到 100%, 远高于其他算法。

表 3 不同转速(载荷)下各模型准确性比较

电机转速/ ($\text{r}\cdot\text{min}^{-1}$)	载荷/ hp	准确率/%			
		BP 神经 网络	本模型 (QPSO-BP)	遗传算法	粒子群 算法
1 797	0	93.75	100	97.50	98.75
1 772	1	91.25	100	98.75	97.50
1 750	2	97.50	100	96.25	95.00

根据以上实验结果可以得知:

(1)利用 EEMD 方法与小波去噪对滚动轴承原始振动信号进行处理, 可有效提取 IMF 分量, 同时抑制噪声干扰。

(2)与遗传算法和粒子群算法对比, 本文所提出的基于 EEMD 能量矩和改进 QPSO-BP 方法能够更准确地对滚动轴承故障进行诊断, 且稳定性好, 故障诊断正确率达到 100%。

6 结论

本文提出一种基于 EEMD 能量矩和改进量子粒子群神经网络的滚动轴承故障诊断模型, 先利用 EEMD 将滚动轴承原始故障信号进行分解, 得到若干个 IMF, 利用能量矩的方法将 IMF 信号转换成故障特征, 作为神经网络的输入。利用改进量

子粒子群 BP 神经网络训练相关参数, 得到最优的诊断模型, 该模型能够准确地诊断轴承的正常工况或故障类型, 有较强的稳定性。利用滚动轴承故障原始信号对理论模型进行检验分析, 结果表明本文提出的方法能够有效提取故障特征信息。相比较典型神经网络模型如 BP、粒子群神经网络等, 基于 EEMD 能量矩和改进量子粒子群神经网络可以准确、有效地对滚动轴承进行故障诊断, 且诊断正确率达到 100%。

参考文献:

- [1] Ben Ali J, Fnaiech N, Saidi L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals[J]. Applied Acoustics, 2015, 89:16-27.
- [2] 张超, 陈建军, 郭迅. 基于 EMD 能量熵和支持向量机的齿轮故障诊断方法[J]. 振动与冲击, 2010, 29(10): 216-220.
- [3] Song L, Wang H, Chen P. Vibration-based intelligent fault diagnosis for roller bearings in low-speed rotating machinery[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(8):1887-1899.
- [4] Yan R, Gao R X, Chen X. Wavelets for fault diagnosis of rotary machines: A review with applications[J]. Signal Processing, 2014, 96:1-15.
- [5] Han D, Zhao N, Shi P. Gear fault feature extraction and diagnosis method under different load excitation based on EMD, PSO-SVM and fractal box dimension[J]. Journal of Mechanical Science and Technology, 2019, 33(2):487-494.
- [6] Huang N E, Wu M L C, Long S R, et al. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 2003, 459(2037):2317-2345.
- [7] Yu D, Cheng J, Yang Y. Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings [J]. Mechanical Systems and Signal Processing, 2005, 19(2):259-270.
- [8] Yang Y, Yu D, Cheng J. A roller bearing fault diagnosis method based on EMD energy entropy and ANN[J]. Journal of Sound and Vibration, 2006, 294(1/2):269-277.
- [9] 曹精明, 邵忍平, 胡文涛. HOC 与 EMD 结合的齿轮损伤检测研究[J]. 仪器仪表学报, 2011, 32(4):729-735.
- [10] 胡爱军, 孙敬敬, 向玲. 经验模态分解中的模态混叠问题[J]. 振动. 测试与诊断, 2011, 31(4):429-434.

- [11] Wu Z, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1):1-41.
- [12] 张立国, 康乐, 金梅, 等. 一种基于 EEMD-SVD 和 FCM 的轴承故障诊断方法[J]. *计量学报*, 2016, 37(1): 67-70.
- [13] Li H, Liu T, Wu X, et al. Application of EEMD and improved frequency band entropy in bearing fault feature extraction[J]. *ISA Transactions*, 2019, 88:170-185.
- [14] 程军圣, 王健, 桂林. 改进的 EEMD 方法及其在滚动轴承故障诊断中的应用[J]. *振动与冲击*, 2018, 37(16): 51-56.
- [15] 彭畅, 柏林, 谢小亮. 基于 EEMD、度量因子和快速峭度图的滚动轴承故障诊断方法[J]. *振动与冲击*, 2012, 31(20):143-146.
- [16] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. *振动与冲击*, 2018, 37(19):124-131.
- [17] 于婷婷. 基于 BP 神经网络的滚动轴承故障诊断方法[D]. 大连: 大连理工大学, 2008.
- [18] Nguyen V H, Cheng J S, Yu Y, et al. An architecture of deep learning network based on ensemble empirical mode decomposition in precise identification of bearing vibration signal[J]. *Journal of Mechanical Science and Technology*, 2019, 33(1):41-50.
- [19] Yan X, Jia M. A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing[J]. *Neurocomputing*, 2018, 313:47-64.
- [20] Bearing Data Center of Case Western Reserve University. Seeded fault test data[DS/OL]. [2019-06-21]. <https://csegroups.case.edu/bearingdatacenter/pages/download-data-file>.

Rolling bearing fault diagnosis based on EEMD energy moment and improved quantum particle swarm optimization neural network

MIN Wenjun¹, LI Guoping^{1*}, HAN Tongpeng², XIANG Sitong¹, LAI Wenfeng¹

(1. Faculty of Mechanical Engineering & Mechanics, Ningbo University, Ningbo 315211, China;

2. Huaxia Happiness Industry New City (Hangzhou) Co., Ltd., Hangzhou 310000, China)

Abstract: In light of the nonlinear and periodic shock characteristics of rolling bearing fault vibration signals, a feature extraction method based on ensemble empirical mode decomposition (EEMD) energy moment and improved quantum particle swarm neural network is proposed. Based on wavelet denoising, the original signal of the rolling bearing is preprocessed, and the reconstructed fault signal is decomposed by EEMD to obtain multiple eigenmode function components. The energy moment of the required component is calculated by the energy moment method and is normalized. The normalized energy characteristic parameter is used as the parameter input of the quantum particle group BP neural network, and the rolling bearing fault diagnosis is accomplished with the acceleration sensor signal. The vibration signals of the drive end bearings are collected at different speeds (loads), 200 training samples and 80 test samples are acquired, and a fault diagnosis model is established. With this model, the actual rolling bearing data is diagnosed for case study. The experimental results show that the accuracy of 80 samples tested under different speeds (loads) may reach 100%.

Key words: rolling bearing; fault diagnosis; ensemble empirical mode decomposition; energy moment; improved quantum particle swarm

(责任编辑 韩 超)