

基于极点对称模态分解和概率神经网络的轴承故障诊断

张淑清¹ 徐剑涛¹ 姜安琦² 李军锋¹ 宿新爽¹ 姜万录³

1.燕山大学电气工程学院,秦皇岛,066004

2.中南大学信息工程学院,长沙,410006

3.燕山大学机械工程学院,秦皇岛,066004

摘要:针对复杂非线性的滚动轴承系统,提出了极点对称模态分解(ESMD)和概率神经网络(PNN)相结合的滚动轴承故障诊断方法。ESMD将固有模态函数的定义进行扩充,采用内部极点对称直接插值的方法替代外部包络线插值,引入最优的自适应全局曲线(AGM)的概念优化分解的趋势线,并由此确定最佳的模态分解次数。PNN是一种基于核函数逼近的神经网络分类器,将指数函数引入神经网络用来替代S型激活函数并进行重新构造,突出体现了梯度最速下降法的概念,减少实际和预测的输出函数之间的误差。通过对经验模态分解(EMD)、屏蔽经验模态分解(MEMD)和ESMD方法进行信号仿真分解对比,以及采用ESMD和PNN对故障数据进行处理,结果表明,该方法能够更加有效地对故障信号进行识别。

关键词:滚动轴承;极点对称模态分解;概率神经网络;故障诊断

中图分类号:TH17

DOI:10.3969/j.issn.1004-132X.2017.04.009

Fault Diagnosis of Bearings Based on Extreme-point Symmetric Mode Decomposition and Probabilistic Neural Network

ZHANG Shuqing¹ XU Jiantao¹ JIANG Anqi² LI Junfeng¹ SU Xinshuang¹ JIANG Wanlu³

1.Institute of Electrical Engineering,Yanshan University,Qinhuangdao,Hebei,066004

2.School of Information Engineering,Central South University,Changsha,410006

3.College of Mechanical Engineering,Yanshan University,Qinhuangdao,Hebei,066004

Abstract: Aimed at the complex non-linear rolling bearing systems, a new method combining ESMD and PNN was introduced for bearing fault diagnosis. ESMD expanded the definition of the intrinsic mode function, and changed the external envelope interpolation to internal pole symmetric interpolation. An idea of adaptive global mean(AGM) was used to optimize the last remaining modal, thus to determine the optimal number of decomposition. PNN was a neural network classifier based on kernel function approximation. The exponential functions were introduced to the neural network to replace the S type activation functions and to reconstruct the functions, representing the notion of gradient steepest descent method prominently, and reducing the errors between the actual and predicted output functions. Through the decomposing comparison to the simulation signals among empirical mode decomposition(EMD), making empirical mode decomposition(MEMD) and ESMD, and the diagnosis to the bearing vibration data by ESMD and PNN shows that the new method introduced may diagnose the bearing faults more effectively.

Key words: rolling bearing; extreme-point symmetric mode decomposition(ESMD); probabilistic neural network(PNN); fault diagnosis

0 引言

滚动轴承是旋转机械的重要组成部分,其振动信号是各种噪声和轴承的振动信号的叠加,具有非线性和非平稳性特征。处理方法包括傅里叶

变换、小波变换以及自适应信号处理方法经验模态分解(empirical mode decomposition, EMD)等^[1-3]。傅里叶变换和小波变换等时频信号分析方法都是由线性叠加原理发展而来的,对振动信号的非线性非平稳信号不适用^[4]。EMD将采集的滚动轴承的振动信号进行包络分解,获得包含各个主分量的固有模态函数,从而体现出振动信

收稿日期:2016-04-01

基金项目:国家自然科学基金资助项目(51475405,61077071);

河北省自然科学基金资助项目(F2016203496,F2015203413)

号的特征分量信号^[5]。然而其在信号分解过程中出现的模态混叠以及不能自适应地解决欠包络和过包络问题,限制了 EMD 处理信号的能力^[6]。自适应信号处理方法屏蔽经验模态分解(masking empirical mode decomposition, MEMD)使 EMD 法的混叠问题得到有效的解决^[7]。然而,由于 MEMD 在处理信号的过程中添加了掩蔽信号,并且掩蔽信号的选择和处理具有不确定性,在信号的处理过程中不能完全综合所添加的信号,造成了其性能缺陷。

文献[8]研究极点对称模态分解算法,借鉴经验模态分解,采用内部极点对称直接插值的方法替代外部包络线插值,引入最优的自适应全局曲线(adaptive global mean, AGM)的概念来优化分解的趋势线,并由此确定最佳模态分解次数,取得了较好效果。

概率神经网络(probabilistic neural network, PNN)与 BP(back propagation)神经网络相比具有一个相对较快的训练过程,这是因为预先设定的代表训练集的规模保证了最大化和训练样本可以随时添加或删除而无需广泛地再训^[8]。

概率神经网络是一种基于核函数逼近的神经网络分类器,将指数函数引入神经网络用来替代 S 型激活函数并进行重新构造,突出体现了梯度最速下降法的概念,减小实际和预测的输出函数之间的误差。PNN 在处理传统意义上复杂的、非线性的和不精确的问题时具有独特的优势。本文采用 PNN 神经网络故障数据进行处理,更加有效地对故障信号进行识别。

1 信号的 ESMD 分解

1.1 经验模态分解

经验模态分解的原理可以简单表述为

$$x(t) = \sum_{j=1}^n c_j + R \quad (1)$$

其中, R 为残余量; c_j 为信号经过 EMD 分解所产生的固有模态函数(intrinsic mode function, IMF)^[8], n 为信号经 EMD 分解所产生的 IMF 的个数, j 表示第 j 个 IMF 分量。

1.2 极点对称模态分解

经验模态分解中,所分解出的 IMF 分量不是完全正交的,如果信号中的极点分布不均匀或者极点数过于少,EMD 分解就不能进行并且会出现模态混叠现象。极点对称模态分解的方法根据信号的特点,引入最优自适应全局曲线概念优化分解的趋势线,并由此确定最佳模态分解次数^[9-11]。

ESMD 重新定义了 IMF:①局部的极大值点和极小值点是不同的,相邻且相等的极值点作为一个极值点加入到信号分解中,极大值必须是正数,极小值必须是负数;②广义上,IMF 分量应该几乎是包络对称或者极点对称的。

ESMD 并不将信号分解到最后剩余最多的一个极值点,相反,它允许残留成分包含一定数量的极值点。这一过程的优势一方面在于分解的残余分量可以反映整体数据的变化趋势,可以理解为一种最优的自适应全局曲线(adaptive global mean, AGM);另一方面在于可以优化最小二乘法意义上的 AGM 曲线来确定最优的筛选次数。它提供了一个很好的自适应方法的数据拟合,优于一般的最小二乘法。

不同于 EMD 中构建两个不同的外部包络线,ESMD 采用多次对极值点连线的重点进行内部曲线插值。根据以往实验,一般在数据处理中,两次内部曲线插值即可达到标准^[9-11]。数据处理过程中,筛选次数的确定参考均值曲线的原理,采用最佳筛选次数的分解条件。

1.3 极点模态分解算法实现过程

(1) 用 $E_i (i=1, 2, \dots, n)$ 分别将信号 X 所有的极大值点和极小值点进行标记。

(2) 用线段相互连接所有的极值点,并标记这些线段的中点为 $F_i (i=1, 2, \dots, n-1)$ 。

(3) 通过一定的方法分别在左右两个边界添加 F_0 和 F_n 。

(4) 根据上述 $1+n$ 个点构造 p 个内插值曲线 $L_1, L_2, \dots, L_p (p=1, 2, \dots)$, 并且计算它们的均值:

$$L^* = (L_1 + L_2 + \dots + L_p) / p \quad (2)$$

(5) 令 $X - L^*$, 并重复上述 4 个步骤,直到 $|L^*| \leq \epsilon$ (3)

式中, ϵ 为允许的误差。

或者筛选次数达到最大值 K 。此时,得到第一个模态函数 M_1 。

(6) 对于剩余部分 $X - M_1$ 重复上述 5 个步骤,可以依次得到 M_2, M_3, \dots , 直到最后的剩余分量 R 含有不超过约定的极点数。

(7) 在有限整数区间 $[K_{\min}, K_{\max}]$ 改变最大筛选次数 K 的取值,重复上述 6 个步骤。然后计算 $X - R$ 的方差 σ^2 并作关于 σ/σ_0 和 K 的曲线图,其中 σ_0 为信号 X 的标准差。

(8) 找到区间 $[K_{\min}, K_{\max}]$ 中对应于 σ/σ_0 最小值时 K 的最小值 K_0 , 用 K_0 重复前 6 个步骤,得到最佳的 ESMD 分解出的各 IMF 分量。与此同

时,得到的 R 即为最优的 AGM 曲线。

通常选择 $\varepsilon=0.001\sigma_0$, 并且选择比率 $v=\sigma/\sigma_0$ 去反映 AGM 曲线的最优程度。

此时原始数据和 AGM 曲线可分别用 $X=\{x_i\}$ 和 $R=\{r_i\}$ 表示, $i=1,2,\cdots,n$ 。

定义数据的总体均值为

$$\bar{X} = \sum_{i=1}^n x_i / n \quad (4)$$

数据的方差为

$$\sigma_0 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2 \quad (5)$$

AGM 曲线的方差为

$$\sigma = \frac{1}{n} \sum_{i=1}^n (x_i - r_i)^2 \quad (6)$$

经过分解,原始的时间序列 X 可表示为

$$X = \sum_{j=1}^n M_j + R \quad (7)$$

利用 ESMD 将时间序列 X 分解成一系列 IMF 和一个趋势项。

1.4 ESMD 与 EMD、MEMD 的对比

EMD 将信号分解成包含不同主频分量的 IMF 分量,然而,当信号存在异常干扰或信号发生间断跳跃时,这些突变信号的频率往往要高于原信号的频率,出现模态混叠,无法将不同的主频分量有效地分离到不同的 IMF 分量中,使得一个固有模态函数分量中出现多个相近的主频分量,所以信号内部的特征无法真正通过 EMD 分解出的 IMF 分量表现出来^[12]。模态混叠的出现导致 EMD 对信号的分解不能进行有效分析。屏蔽经验模态分解(MEMD)法由于掩盖信号的不确定性造成其对信号的分解也会出现不确定性。

取两个等幅值的单频信号的叠加形式如下:

$$x_1(t) = \sin 2\pi t + \sin 1.2\pi t \quad (8)$$

对该信号 $x_1(t)$ 进行 EMD 分解,如图 1 所示,信号 $x_1(t)$ 的频谱如图 1a 所示, $f_1=1\text{ Hz}$, $f_2=0.6\text{ Hz}$; 图 1b 是 EMD 分解后的 IMF1 的频谱图。从图 1b 中可以看出,IMF1 分量并不只包含一个主频率分量,它不仅包含主要的 1 Hz 高频成分而且含有部分 0.6 Hz 的低频成分,充分体现了经验模态分解过程中出现的模态混叠问题。在实际应用中,信号形式十分复杂,相邻的频率成分大小比较接近,难以区分,这就使得 EMD 分解不可避免地存在模态混叠问题。

采用 ESMD 对信号 $x_1(t)$ 进行处理后的频谱图见图 2。通过对比图 2 和图 1,可以看出 ESMD 分解后的 IMF1 分量中只包含单一的主频分量,不存在 ESMD 分解所存在的模态混叠问题。




图 1 $x_1(t)$ 的 EMD 分解

Fig.1 EMD of $x_1(t)$




图 2 $x_1(t)$ 的 ESMD 分解

Fig.2 ESMD of $x_1(t)$

为了综合对比 EMD、MEMD 和 ESMD 的效果,取信号:

$$x_2(t) = \sin(2\pi f_1 f_s n) + \sin(2\pi f_2 f_s n) \quad (9)$$

其中, $f_s=1024\text{ Hz}$, $f_1=177.6\text{ Hz}$, $f_2=100\text{ Hz}$ 。信号经 EMD、MEMD 和 ESMD 处理结果如图 3 所示。

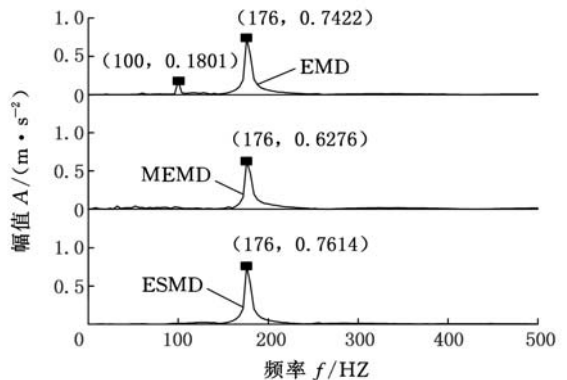


图 3 $x_2(t)$ 的 EMD、MEMD、ESMD 对比

Fig.3 Comparison among EMD, MEMD and ESMD of $x_2(t)$

由图 3 三种方法的对比可以看出, MEMD 由于掩盖信号的加入,在分解后会出现信号的失真,造成物理意义上的分解错误,显然 ESMD 分解方

法很好地解决了模态混叠问题。

2 概率神经网络

典型的 PNN 神经网络如图 4 所示。它一般包括 4 个组成部分,即输入层、模式层、叠加层和输出层。输入层是第一层神经元。每个输入神经元在训练 / 测试数据集代表一个单独的属性,输入的数目与数据集中的属性数相等。输入数据的值乘以适当的权重,并被传送到模式层。输出层通常只包含一个类的最后一层,因为通常只有一个输出被要求。在训练阶段,目标是确定最准确的权重分配给连接线。在这个阶段,输出被反复计算,并与训练 / 测试数据集所产生的优选输出的结果进行比较^[13-15]。

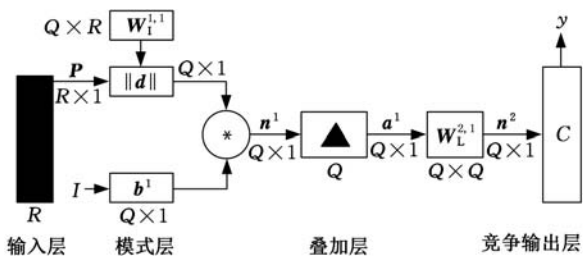


图 4 概率神经网络

Fig.4 Schematic of probabilistic neural network

在图 4 输入层表示中, R 为所输入元素的数目。 $W_i^{1,1}$ 为权值向量, $\|d\|$ 为计算输入的元素与权值向量之间的欧式距离。计算的公式如下:

$$a_i = g_r(\|_i W_i^{1,1} - P \| b_i^{1,1}) \tag{10}$$

$$y = g_c(W_L^{2,1} - a^1) \tag{11}$$

式中, a_i^1 为向量 a^1 的第 i 个元素; $g_r(\cdot)$ 为径向基传递函数; P 为输入层含有 R 个元素数目的输入向量; $_i W_i^{1,1}$ 表示向量 $W_i^{1,1}$ 中第 i 行元素构成的新向量; $b_i^{1,1}$ 为向量 b^1 的第 i 个元素; $g_c(\cdot)$ 函数为竞争传递函数; $W_L^{2,1}$ 为权值。

PNN 具有如下优良特性: ① 网络学习训练的过程简单, 能较快地达到训练标准; ② PNN 神经网络对数据的分类准确, 只要训练样本足够大, 可以达到非常准确的分类效果, 并且噪声对其分类效果影响低; ③ PNN 可以用线性计算方法计算非线性数据, 并能够以任意精度逼近^[16]。

3 采用 ESMD 和 PNN 的轴承故障诊断流程

- (1) 对振动信号进行 ESMD 分解。
- (2) 分别将得到的 IMF 分量与原信号的相关系数进行计算并排序, 取前 n 个 IMF 分量用来表征振动信号(n 的取值根据具体的振动信号分解而定)。相关表达式如下:

$$D(X) = E(X - E(X))^2 \tag{12}$$

$$cov(X,Y) = E((X - E(X))(Y - E(Y))) \tag{13}$$

$$\rho_{XY} = \frac{cov(X,Y)}{\sqrt{D(X)} \sqrt{D(Y)}} \tag{14}$$

式中, $D(X)$ 为信号 X 的标准差; $E(X)$ 为信号 X 的均值; $cov(X,Y)$ 为信号 X 和信号 Y 的协方差; ρ_{XY} 为信号 X 和信号 Y 的相关性系数。

(3) 为了便于对数据进行 PNN 训练和分类, 将上述所得相关性大的 IMF 分量进行能量的计算^[17]:

$$E_i = \int_{-\infty}^{+\infty} |M_i(t)| dt \tag{15}$$

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

构造出向量 T , 并对所得向量 T 进行整体归一化处理:

$$T = (E_1, E_2, \dots, E_n) \tag{16}$$

$$E' = (\sum_{i=1}^n |E_i|^2)^{\frac{1}{2}} \tag{17}$$

$$T' = (\frac{E_1}{E'}, \frac{E_2}{E'}, \dots, \frac{E_n}{E'}) \tag{18}$$

向量 T' 即为归一化后的能量特征向量。

(4) 将 T' 作为特征向量输入到 PNN 中进行训练。

4 故障诊断实例

本实验采用美国凯斯西储大学 (Case Western Reserve University) 的滚动轴承故障数据。实验装置如图 5 所示, 主要以 SKF6205 型深沟球轴承数据为仿真数据。




图 5 轴承故障诊断实验仪器

Fig.5 Experimental instrument of bearing fault diagnosis

实验中, 分别随机选取风扇端以采样频率 12 kHz 采集滚动轴承的正常、滚动体故障、外圈故障和内圈故障 4 种类型的故障信号共 240 组, 每组选取 1500 个点。240 组数据中, 200 组数据作为训练样本, 40 组作为测试样本。

首先对上述 4 种轴承振动数据进行 ESMD 分解, 并计算分解后的包含各个单主频的固有模态函数与信号的相关系数, 根据相关系数选取了 7

组经 ESMD 处理过的内蕴模态函数作为 PNN 神经网络训练的特征分量。然后对这些特征分量进行整体归一化,分别标记滚动轴承正常、滚动体故障、外圈故障和内圈故障 4 种类型的故障数据为 1、2、3、4,然后输入到 PNN 神经网络中进行分类器的分类。ESMD 分解振动信号如图 6 所示。




图 6 ESMD 分解振动信号

Fig.6 The experimental results after ESMD

PNN 神经网络训练中初始的 SPREAD 系数 $\eta_s = 1$ 。随着 SPREAD 系数的逐渐减小,训练效果会逐步变好。当 $\eta_s = 0.1$ 时,PNN 神经网络训练结果见图 7。当 $\eta_s = 0.08$ 时,PNN 神经网络训练结果见图 8。从图中可知,实验结果达到了预期效果。

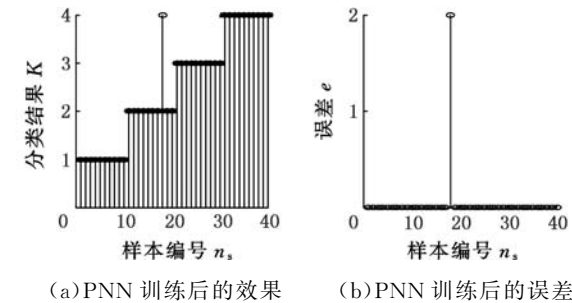



图 7 $\eta_s = 0.1$ 时 ESMD 分解后 PNN 训练结果

Fig.7 The result of using ESMD and PNN to diagnosis the rolling bearing fault under $\eta_s = 0.1$

为了说明本文方法的优越性,同样信号采用 EMD 分解、MEMD 分解和 PNN 训练,PNN 训练结果如图 9~图 12 所示。

图 9 和图 10 所示均为在信号分解的方法中




(a)PNN 训练后的效果

(b)PNN 训练后的误差

图 8 $\eta_s = 0.08$ 时 ESMD 分解后 PNN 训练结果

Fig.8 The result of using ESMD and PNN to diagnosis the rolling bearing fault under $\eta_s = 0.08$

采用了 EMD 后的效果。与图 7、图 8 对比可以明显看出,ESMD 方法处理过的数据相对于 EMD 处理过的数据在初始条件和变化条件下,数据的收敛状态与速度都要好很多。




(a)PNN 训练后的效果

(b)PNN 训练后的误差

图 9 $\eta_s = 0.1$ 时 EMD 分解后 PNN 训练结果

Fig.9 The result of using EMD and PNN to diagnosis the rolling bearing fault under $\eta_s = 0.1$




(a)PNN 训练后的效果

(b)PNN 训练后的误差

图 10 $\eta_s = 0.08$ 时 EMD 分解后 PNN 训练结果

Fig.10 The result of using EMD and PNN to diagnosis the rolling bearing fault under $\eta_s = 0.08$




(a)PNN 训练后的效果

(b)PNN 训练后的误差

图 11 $\eta_s = 0.1$ 时 MEMD 分解后 PNN 训练结果

Fig.11 The result of using MEMD and PNN to diagnosis the rolling bearing fault under $\eta_s = 0.1$



(a) PNN 训练后的效果 (b) PNN 训练后的误差

图 12 $\eta_s=0.08$ 时 MEMD 分解后 PNN 训练结果

Fig.12 The result of using MEMD and PNN to diagnosis the rolling bearing fault under $\eta_s=0.08$

图 11 与图 12 所示均为在信号分解的方法中采用了 MEMD 后的效果。与图 9、图 10 对比发现, MEMD 处理信号后经 PNN 训练效果要好于 EMD 方法, 在信号的初始条件以及变化条件下, 其收敛速度都要高于 EMD 方法。但是与图 7、图 8 相比, ESMD 对信号的处理优于 MEMD 方法。

由上述分析可知, 随着 SPREAD 系数的逐渐减小, 经 ESMD 分解的信号收敛较快, 分类结果准确、误差小, 证明了 ESMD 方法的优越性。

5 结束语

本文通过极点模态分解将机械振动信号分解成多个 IMF 函数, 以 IMF 分量作为信号的特征向量, 采用概率神经网络对样本数据进行训练, 对测试数据进行辨识, 构成了旋转机械故障诊断的新方法。通过实验证明该方法可以有效地区分滚动轴承的正常、内圈、外圈、滚动体故障等故障状态, 与传统的经验模态分解等方法相比, 在提取信号的特征向量方面具有分解彻底、残余量可以表征信号振动趋势等优点, 便于在故障初期发现故障并及时消除。实验结果表明, 采用 ESMD 和 PNN 相结合的方法能够更有效地对不同故障类型信号进行诊断与识别。

参考文献:

- [1] LI Yongbo, XU Minqiang, WANG Rixin, et al. A Fault Diagnosis Scheme for Rolling Bearing Based on Local Mean Decomposition and Improved Multi-scale Fuzzy Entropy[J]. Journal of Sound and Vibration, 2016, 360: 277-299.
- [2] 赵志宏. 基于振动信号的机械故障特征提取与诊断研究[D]. 北京: 北京交通大学, 2012.

- [3] 钟先友. 旋转机械故障诊断的时频分析方法及其应用研究[D]. 武汉: 武汉科技大学, 2014.
- [4] ZHONG Xianyou. Research on Time-frequency Analysis Methods and Its Applications to Rotating Machinery Fault Diagnosis [D]. Wuhan: Wuhan University of Science and Technology, 2014.
- [5] GILLES J. Empirical Wavelet Transform [J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [6] 黄建, 胡晓光, 巩玉楠. 基于经验模态分解的高压断路器机械故障诊断方法[J]. 中国电机工程学报, 2011, 31(12): 108-113.
- [7] HUANG Jian, HU Xiaoguang, GONG Yunan. Machinery Fault Diagnosis of High Voltage Circuit Breaker Based on Empirical Mode Decomposition [J]. Proceedings of the CSEE, 2011, 31(12): 108-113.
- [8] 时培明, 李庚, 韩东颖. 基于改进 EMD 的旋转机械耦合故障诊断方法研究[J]. 中国机械工程, 2013, 24(17): 2367-2372.
- [9] SHI Peiming, LI Geng, HAN Dongying. Study on Coupling Faults of Rotary Machinery Diagnosis Method Based on Improved EMD [J]. China Mechanical Engineering, 2013, 24(17): 2367-2372.
- [10] DEERING R, KAISER J F. The Use of a Masking Signal to Improve Empirical Mode Decomposition [C]//Acoustics, Speech, and Signal Processing, 2005. Pennsylvania, 2005: 485-488.
- [11] 全学海, 丁宣浩, 蒋英春. 基于 EMD 和概率神经网络的说话人识别[J]. 桂林电子科技大学学报, 2012, 30(2): 108-112.
- [12] QUAN Xuehai, DING Xuanhao, JIANG Yingchun. Speaker Recognition Based on EMD and Probabilistic Neural Networks [J]. Journal of Guilin University of Electronic Technology, 2012, 30(2): 108-112.
- [13] WANG Jinliang, LI Zongjun. Extreme-point Symmetric Mode Decomposition Method for Data Analysis [J]. Advances in Adaptive Data Analysis, 2013, 5(3): 1350015.
- [14] LI Huifeng, WANG Jinliang, LI Zongjun. Application of ESMD Method to Air-sea Flux Investigation [J]. International Journal of Geosciences, 2013, 4(5): 8-11.
- [15] 王金良, 李宗军. 可用于气候数据分析的 ESMD 方法[J]. 气候变化研究快报, 2014(3): 1-5.
- [16] WANG Jinliang, LI Zongjun. The ESMD Method for Climate Data Analysis[J]. Climate Change Research Letters, 2014(3): 1-5.
- [17] 包红燕. 基于 MEMD 和条件熵相空间重构的滚动轴承故障诊断[D]. 秦皇岛: 燕山大学, 2014.

- BAO Hongyan. Rolling Bearing Fault Diagnosis Based on Masking Empirical Mode Decomposition and Phase Space Reconstruction of Conditional Entropy [D]. Qinhuangdao: Yanshan University, 2014.
- [13] CHEN Xianye, ZHOU Jianzhong, XIAO Han. Fault Diagnosis Based on Comprehensive Geometric Characteristic and Probability Neural Network [J]. Applied Mathematics and Computation, 2014, 230(3): 542-554.
- [14] WANG Changqing, ZHOU Jianzhong, QING Hui. Fault Diagnosis Based on Pulse Coupled Neural Network and Probability Neural Network [J]. Expert Systems with Applications, 2011, 38(11): 14207-14313.
- [15] 刘凤龙, 宋艺. 基于 EMD 与 PNN 的机械故障检测 [J]. 计算机应用与软件, 2010, 27(9): 237-239.
- LIU Fenglong, SONG Yi. Machinery Fault Diagnosis Based on EMD and PNN [J]. Computer Applications and Software, 2010, 27(9): 237-239.
- [16] 孟宗, 胡猛, 谷伟明, 等. 基于 LMD 多尺度熵和概率神经网络的滚动轴承故障诊断方法 [J]. 中国机械工程, 2016, 27(4): 433-437.
- MENG Zong, HU Meng, GU Weiming, et al. Rolling Bearing Fault Diagnosis Method Based on LMD Multi-scale Entropy and Probabilistic Neural Network [J]. China Mechanical Engineering, 2016, 27(4): 433-437.
- [17] 肖韬, 袁兴中, 唐清华, 等. 基于概率神经网络的城市湖泊生态系统健康评价研究 [J]. 环境科学学报, 2013, 33(11): 3166-3172.
- XIAO Tao, YUAN Xingzhong, TANG Qinghua, et al. Investigation of Health Assessment for Urban Lakes System Based on Probabilistic Neural Networks [J]. Acta Scientiae Circumstantiae, 2013, 33(11): 3166-3172.

(编辑 王旻玥)

作者简介: 张淑清, 女, 1966 年生。燕山大学电气工程学院教授、博士研究生导师。主要研究方向为弱信号检测、智能信号处理、故障诊断。发表论文 50 余篇。E-mail: zhshq-yd@163.com。

徐剑涛, 男, 1992 年生。燕山大学电气工程学院硕士研究生。

姜安琦, 女, 1995 年生。中南大学信息科学与工程学院本科生。

李军峰, 男, 1994 年生。燕山大学电气工程学院硕士研究生。

宿新爽, 女, 1993 年生。燕山大学电气工程学院硕士研究生。

姜万荣, 男, 1964 年生。燕山大学机械工程学院教授、博士研究生导师。

(上接第 414 页)

- [3] 黄涛, 曹建国, 张杰. 一种提高热连轧机液压活套系统伺服控制响应速度的方法 [J]. 中国机械工程, 2008, 19(11): 1351-1353.
- HUANG Tao, CAO Jianguo, ZHANG Jie. A Way to Effective Response Characteristics of Hydraulic Loopers Servo Control System in Hot Strip Mills [J]. China Mechanical Engineering, 2008, 19(11): 1351-1353.
- [4] STEINBOECK A, MÜHLBERGER G, KUGI A, et al. Control of Strip Tension in a Rolling Mill Based on Loopers and Impedance Control [J]. IFAC Proceedings, 2014, 47(3): 10646-10651.
- [5] ZHONG Zhaozhun, WANG Jingcheng, ZHANG Jianmin, et al. Looper-tension Sliding Mode Control for Hot Strip Finishing Mills [J]. Journal of Iron and Steel Research, International, 2012, 19(1): 23-30.
- [6] 邹俊, 傅新, 杨华勇, 等. 精轧张力系统的仿真与试验 [J]. 吉林大学学报(工学版), 2008, 38(2): 354-359.
- ZOU Jun, FU Xin, YANG Huayong, et al. Numerical Simulation and Experimental Investigation into Tension Control System for the Hot Strip Finishing Mill [J]. Journal of Jilin University (Engineering and Technology Edition), 2008, 38(2): 354-359.
- [7] CHEN Jinxiang, YANG Weidong, SUN Yang, HONG Guang. H^∞ Control of Looper-tension Control Systems Based on a Discrete-time Model [J]. Journal of Iron and Steel Research, International, 2013, 20(10): 28-31.
- [8] 陶桂林, 刘超. 热连轧机组活套张力力矩的精确计算 [J]. 轧钢, 2014, 31(3): 20-22.
- TAO Guilin, LIU Chao. Accurate Calculation of Loop Tension Moment of Hot Strip Mill [J]. Steel Rolling, 2014, 31(3): 20-22.
- [9] 刘兴华, 迁钢 2160 热轧液压活套软接触控制的研究与应用 [J]. 冶金自动化, 2012, 36(6): 58-62.
- LIU Xinghua. Research and Application of Soft-touch Control for Hydraulic Loop in 2160 Hot Rolling Mill of Qiangang [J]. Metallurgical Industry Automation, 2012, 36(6): 58-62.

(编辑 王旻玥)

作者简介: 姬亚锋, 男, 1986 年生。太原科技大学重型机械教育部工程研究中心讲师。主要研究方向为金属加工智能控制。发表论文 7 篇。E-mail: jyf0109@126.com。

田敏, 女, 1992 年生。太原科技大学电子信息工程学院硕士研究生。

郭鹏程, 男, 1991 年生。太原科技大学重型机械教育部工程研究中心硕士研究生。

胡啸, 男, 1986 年生。太原科技大学重型机械教育部工程研究中心讲师。

刘光明, 男, 1982 年生。太原科技大学重型机械教育部工程研究中心副教授。