

基于定量小波基选取与改进 LDB 算法的机械故障诊断

刘岩¹, 杨晶^{1,2}

(1. 南阳理工学院 软件学院, 河南 南阳 473004; 2. 北京科技大学 计算机与通信工程学院, 北京 100083)

摘要: 通过研究信息论中的各种测度, 提出了一种以信息论中的共信息熵来开展故障信号分析的定量小波基选取的方法; 同时针对局域判别基算法 (Local Discriminate Bases, LDB) 自身存在的一些问题, 提出了一种基于改进的局域判别基理论的最优小波基分解算法, 构造了以局域判别基空间上的结点能量为元素的特征矢量, 并在滚动轴承上进行了实验研究; 实验分析表明, 该算法可以有效地识别旋转机械系统中不同严重程度故障, 且与原始的 LDB 算法相比, 改进后的 LDB 算法对提高识别率和降低计算复杂度都有着明显的优势。

关键词: 机械故障诊断; 小波包分解; 定量小波基选取; 改进局域判别基; 支持向量机

Rotating Machine Fault Diagnosis Based on Quantitative Wavelet Base Selection and Improved LDB

Liu Yan¹, Yang Jing^{1,2}

(1. School of Software, Nanyang Institute of Technology, Nanyang 473004, China; 2. School of Computer & Communication Engineering, Beijing University of Science & Technology, Beijing 100083, China)

Abstract: This paper presents an effective approach for rotating machine fault diagnosis, based on quantitative wavelet selection and improved local discriminate bases. Mutual information entropy is utilized as a quantitative measure to select the most suitable base wavelet for wavelet packet transform. Then an improved local discriminate bases method based on the normalized energy difference and relative entropy is used to choose the optimal set of orthogonal wavelet subspaces. After that, two optimal sets of orthogonal subspaces from wavelet packet decomposition have been obtained and the energy features extracted from the subspaces appearing in both sets will be selected as input to the support vector machine (SVM) to diagnose the fault states of rotating machines. Experiment study conducted from a rolling bearing test setup has verified the effectiveness of the proposed method for machine defect severity evaluation.

Keywords: fault diagnosis; wavelet packet decomposition; quantitative wavelet selection; improved local discriminate bases; support vector machine

0 引言

由于机械设备在故障的形成与发展过程中产生的振动信号具有瞬态性和非平稳性^[1], 所以傅里叶变换对于这类信号的分析具有一定的局限性。而各种非平稳信号处理方法如时频分析、小波变换和希尔伯特-黄变换等可用于此类信号的分析, 其中小波变换作为短时傅里叶变换的延伸, 由于具有变时频窗口的信号分析能力 (即高频信号部分时间分辨率高而低频信号部分频率分辨率高) 及多尺度特性, 从一开始就受到了从事机械状态检测与故障诊断的研究者广泛的关注。此外, 为了获取更为精细的分解结果, 研究者们又对小波变换进行了改进, 对小波变换得到的细节信号也进行了进一步的分解^[2], 从而提出了小波包变换。近年来, 国内外对小波包变换在机械故障诊断领域的应用上做了大量有价值的研究工作。例如, 1996年, Y. Wu 和 R. Du 将小波包变换算法引入到了旋转机械运行

过程的信号监测中, 给出了振动信号全频带范围内的小波包分频带能量分布^[3]; 2006年, 王仲生等把小波分析中的离散小波变换和小波包分解与重构用于消除噪声以实现早期故障的快速诊断^[4]; 2009年, 孟凡龙等利用小波包对信号进行特征向量的提取并结合支持向量机实现对各种碰撞故障的识别^[5]。在这些研究中, 研究者大多选用了小波包分解最底层的系数来提取故障信号特征。然而由于小波包分解是在时频平面上对信号的高频和低频成分同时进行分解, 从而形成一个超完备的正交小波基库, 最底层的小波包系数并不一定能最好地反映振动信号的特征, 因而如何从这样的正交小波基库中找出最能表现信号多尺度特征的正交时频空间子集, 成为了提高诊断准确度和有效性的主要难题。为了解决这一问题, 研究者提出了一种利用判别测度选取最优正交基的局域判别基 (LDB) 算法^[6-7], 随后 LDB 算法被迅速应用于语音信号分析^[8]、生理信号分析^[9-10]以及振动信号处理^[11]等领域。从这些研究当中, 我们不难看出可区分度量的选取直接影响着 LDB 算法的准确率。目前, 常用的可区分度量有欧氏距离、相对熵、对称相对熵、归一化能量差、相关系数等。然而, 事实上, 大多数研究者只是选用了其中的一种可区分度量来选取最优正交基, 为了更加全面地刻画信号特征, 可结合多种可区分度量来改进 LDB 算

收稿日期: 2013-12-19; 修回日期: 2014-01-28。

基金项目: 河南省科技攻关项目 (122102210563); 河南省科技攻关项目 (132102210215)。

作者简介: 刘岩 (1978-), 女, 河南南阳人, 硕士, 讲师, 主要从事计算机应用和故障检测等方面的研究。

法以便更好地衡量类间信号的差异程度。

本文将提出一种基于改进局域判别基和定量小波选取的综合机械故障诊断方法。首先结合相对熵和归一化能量差两种可区分度量改进 LDB 算法并将其应用于小波包分解最优正交基的选择中。此外，信息论中的共信息熵将用来开展故障信号分析中的量化基小波选择的理论与实验研究。实际的实验分析结果表明，该方法可以有效地提取振动信号的故障特征，并能成功地对滚动轴承的工作状态和故障类型进行分类。

1 小波包分解基本原理

小波包变换作为离散小波变换的延伸可由一个快速金字塔式算法推导得到^[19]。在数学上，一个小波包由一组线性组合的小波函数构成，它可以由下面的递归关系表示：

$$\begin{aligned} \psi^{2k}(t) &= \sqrt{2} \sum_n h(n) \psi^k(2t-n) \\ \psi^{2k+1}(t) &= \sqrt{2} \sum_n g(n) \psi^k(2t-n) \end{aligned} \quad (1)$$

其中： $\psi^0(t) = \phi(t)$ 为尺度函数， $\psi^1(t) = \psi(t)$ 为小波函数， $h(n)$ 和 $g(n)$ 代表一对与尺度函数和小波函数相关的共轭镜像滤波器组系数，且满足公式 $g(n) = (-1)^n h(1-n)$ ，即两系数也具有正交关系。每一次分解，共轭镜像滤波器组就把输入离散信号分解成一个低频的粗略逼近和一个高频的细节部分。时域信号 $\alpha(t)$ 可分解为：

$$\begin{aligned} \alpha_{j+1}^{2k}(t) &= \sum_m h(m-2n) \alpha_j^k(t) \\ \alpha_{j+1}^{2k+1}(t) &= \sum_m g(m-2n) \alpha_j^k(t) \end{aligned} \quad (2)$$

这里 $\alpha_j^k(t)$ 表示小波包分解中第 j 层，第 k 个子空间的小波包系数， m 为小波包系数的个数。根据公式 (2) 可知，每个细节系数向量和每个近似向量都能分解成两部分。也就是说，对于一个信号 $\Omega_{0,0}$ ，它能以一个完整二叉树的形式分解成 2^j 个小波包节点 $\Omega_{j,k}$ ，具体分解结果如图 1 所示。每个子空间 $\Omega_{j,k}$ 可由一系列基向量 $\{\alpha_{j,k,m}\}_{m=0}^{2^N-j-1}$ 生成，其中 2^N 为信号长度。因此，信号 x_i 可由以下等式表示：

$$x_i = \sum_{j,k,m} [\alpha_{j,k,m}]_i \cdot \omega_{j,k,m} \quad (3)$$

由图 1 所示的 3 层小波包分解图可以看出，选择不同的正交子空间，小波包变换有不同的分解形式。例如正交子空间集 $\{\Omega_{3,0}, \Omega_{3,1}, \Omega_{3,2}, \Omega_{3,3}, \Omega_{3,4}, \Omega_{3,5}, \Omega_{3,6}, \Omega_{3,7}\}$ 或 $\{\Omega_{2,0}, \Omega_{3,2}, \Omega_{3,3}, \Omega_{3,4}, \Omega_{3,5}, \Omega_{3,6}, \Omega_{3,7}\}$ 或 $\{\Omega_{2,0}, \Omega_{2,1}, \Omega_{2,2}, \Omega_{3,6}, \Omega_{3,7}\}$ 都构成了一组完备的正交子空间集。因此，如何选择适合分类的最优子空间将成为本文研究的主要内容。




图 1 三层小波包分解树

2 改进局域判别基 (LDB) 算法

我们利用小波理论来分析旋转机械的振动信号时，目的是从这些信号中提取相应的特征并根据这些特征来判断其工作状态（比如是否发生了故障或者故障的严重程度如何）。由于小

波包分解后的信号频谱存在“子带”和“父带”间的相互重叠，如何从这些相互重叠的子空间中找到一组完备、互不重叠且具有较好分类效果的子空间将是局域判别基算法解决的问题。

LDB 算法是一种裁剪算法，它利用某一给定的可区分度量来区分不同类别信号间具有较高区分特性的子带，并从小波包分解的结果中寻找一组含有较高判别能力的最优完备正交基。

假设给定一组含有 L 类不同信号的数据 $\{\{x_i^{(l)}\}_{i=1}^{N_l}\}_{l=1}^L$ ，其中 N_l 为信号类别为 l 的信号个数。令 $B_{j,k}$ 为子空间 $\Omega_{j,k}$ 中小波包基向量矩阵， $A_{j,k}$ 是经过 LDB 算法得到的 $\Omega_{j,k}$ 空间中的最优局域判别基， $\Delta_{j,k}$ 为 $\Omega_{j,k}$ 空间的 L 类样本的可区分度量值。

第一步：利用小波包分解方法对每个信号进行分解；

第二步：对每一类分解后的信号的小波系数根据公式 (3) 和 (4) 构造时频能量图 $C_l (l = 1, \dots, L)$ ；

$$C_l(j,k,m) = \sum_{i=1}^{N_l} (a_{j,k,m}^T x_i^{(l)})^2 / \sum_{i=1}^{N_l} \|x_i^{(l)}\|^2 \quad (4)$$

第三步：设置 $A_{j,k} = B_{j,k}$ ，然后利用公式 $\Delta_{j,k} = D(\{C_l(j,k,\dots)\}_{l=1}^L)$ 计算可区分度量值， $k = 0, \dots, 2^j - 1$ ，其中 $D(\cdot)$ 表示某一给定的可区分度量；

第四步：利用自底向上的快速搜索法确定最优子空间 $A_{j,k}$ ，其中 $j = J - 1, \dots, 0, k = 0, \dots, 2^j - 1$ ；令 $\Delta_{j,k} = D(\{C_l(j,k,\dots)\}_{l=1}^L)$ ，如果小波分解树上父节点的判别能力大于它的子节点，即 $\Delta_{j,k} \geq \Delta_{j+1,2k} + \Delta_{j+1,2k+1}$ ，则暂时保留该父节点，并将相应子空间舍弃， $A_{j,k} = B_{j,k}$ ，否则便保留这两个子空间，并将父节点的判别能力修改成子空间的判别能力和， $A_{j,k} = A_{j+1,2k} \oplus A_{j+1,2k+1}$ 且 $\Delta_{j,k} = \Delta_{j+1,2k} + \Delta_{j+1,2k+1}$ ；

第五步：根据判别能力大小排列每个选择的分解节点；

第六步：选择 $t (< n)$ 最具有判别能力的分解节点，并提取其对应的小波包分解系数所对应的特征进行信号的分类。

然而需要指出的是，对于某一给定数据集，最佳的 LDB 子带的选择取决于数据集本身和用于区分类别的区分度量值。可区分度量值 (Dissimilarity Measure) 用来确定具有高区分性的小波包子带，其在很大程度上影响到最终的识别率。因此，可区分度量值的选择尤为重要。

为了获得较高的分类精度，研究者研究了大量有意义的可区分度量，这些可区分度量的选择与分类结果的准确率息息相关。近年来，研究人员在不同的工程领域提出了大量的可区分度量，如欧氏距离、对称相对熵、相对熵、归一化能量差、相关关系等等。然而，单一的可区分度量无法捕获某类信号的所有特征信息，尤其是对复杂数据集，如本文的研究对象大型旋转机械的振动信号。此外，多种可区分度量的使用将给分类提供额外的特征维数。因此，本文提出了一种结合归一化能量差 D_1 和相对熵 D_2 两个可区分度量的改进 LDB 算法来实现最优判别子空间的选取。

第一个可区分度量归一化能量差表示两类训练信号对应节点归一化能量间的差异，它能够显示出不同类别的振动信号在时频平面上的能量分布。其定义如下：

$$D_1^{(1,2)} = |E_{1,k}^j - E_{2,k}^j| \quad (5)$$

其中： $E_{1,k}^j$ 和 $E_{2,k}^j$ 分别为第 1 类信号和第 2 类信号在小波

包树第 j 层、第 k 个子空间的归一化能量, 其计算公式如下:

$$E_{j,k} = \frac{\sum_{m=0}^{2^{n_0-j}-1} (\alpha_{j,k,m}^2)}{E_{x_i}} \quad (6)$$

其中: $j=0, 1, \dots, J, k=0, 1, \dots, 2^j-1, n_0=\log_2 n \geq J$ (n 为信号长度, n_0 为最大分解层数), $\alpha_{j,k,m}$ 为小波包树中第 j 层、第 k 个子空间的第 m 个小波包系数, E_{x_i} 则代表振动信号的总能量。

第二个可区分度量相对熵表征了两分布序列间的分离程度。其定义为:

$$D_2^{(1,2)} = \sum_{i=1}^n p_i^{(1)} \log \frac{p_i^{(1)}}{p_i^{(2)}} \quad (7)$$

其中: $n=2^{n_0-j}-1$, 令 p, q 为两个非负序列且满足等式 $\sum_i p_i^{(1)} = \sum_i p_i^{(2)} = 1$ (即 p, q 可视为某种归一化的能量分布),

$p_m(j, k) = \alpha_{j,k,m}^2 / \sum_{i=1}^n |\alpha_{j,k,i}|^2$ 为训练样本信号总能量归一化的各样本信号在 (j, k, m) 处的小波包系数的平方和。

由公式 (5) 和公式 (7) 我们可以得到以下结论: 两类信号差异性越大, 可区分度量值 D_1 和 D_2 越大。

类似地, 对于多类 ($L > 2$) 问题, L 类样本在子空间 $\Omega_{j,k}$ 上的时频能量分布的可区分度量为:

$$\begin{aligned} D_1 &= \sum_{i=1}^{L-1} \sum_{j=i+1}^L D_1^{(i,j)} \\ D_2 &= \sum_{i=1}^{L-1} \sum_{j=i+1}^L D_2^{(i,j)} \end{aligned} \quad (8)$$

改进 LDB 算法与原始 LDB 算法相比较主要是对可区分度量进行了改进, 由之前的单一可区分度量变为多个可区分度量来改进 LDB 算法从而实现最优判别子空间的选取。首先, 利用小波包分解方法对每个信号进行分解; 设置 $A_{j,k} = B_{j,k}$, 利用公式 $\Delta_{j,k} = D_i, i=1, 2, k=0, \dots, 2^j-1$ 计算可区分度量值; 同样地, 利用自底向顶的快速搜索法确定最优子空间 $A_{j,k}$; 随后, 分别选用可区分度量 D_1 和可区分度量 D_2 重复上述步骤, 得到两组完备的正交子空间集。重复出现在这两组正交子空间集的子空间表明不同类信号在该子空间上时频平面上能量分布差异较大且分离程度较大, 因此我们将重复出现在这两组正交子空间集的子空间看作是本文寻找的适合分类的最优子空间; 最后, 我们将选择的 t 个最具有判别能力的最优子空间来构建特征向量, 提取其对应的小波包分解系数所对应的能量特征进行信号的分类。

3 定量小波基选取方法

为确保小波变换在机械故障诊断的有效性, 如何选择最适合信号分解和特征提取的小波基是本文的另一关键问题。由于小波变换的本质是利用伸缩移位后的基小波与待分析信号之间的相关性操作, 因此基小波与待分析信号越相似, 其特征提取的能力越强。而信息论中的各种测度, 比如联合熵、条件熵、共信息熵, 相对熵等, 常用来描述两组数据序列之间的关系, 其数值的大小往往反映了两组数据序列的相似程度。因而本文确定以信息论中的这些测度来指导基小波的选择并重点对共信息熵进行了研究。共信息熵描述了一组数据序列中所含有的另一组数据序列的信息多少, 可用下列的公式来描述:

$$\begin{aligned} I(X;Y) &= \sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} = \\ &= \sum_{x \in X} \sum_{y \in Y} p(x,y) \log p(x,y) - \sum_{x \in X} p(x) \log p(x) - \sum_{y \in Y} p(y) \log p(y) \end{aligned} \quad (9)$$

其中: $p(x, y)$ 表示数据序列 X 和数据序列 Y 的联合概率密度, $p(x)$ 和 $p(y)$ 则分别代表数据序列 X 和数据序列 Y 的概率密度。而公式中 $\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y)$ 则是两个数据序列的联合熵 $H(X, Y)$, $\sum_{x \in X} p(x) \log p(x)$ 和 $\sum_{y \in Y} p(y) \log p(y)$ 则分别代表数据序列 X 和数据序列 Y 的香农熵 $H(X)$ 和 $H(Y)$ 。公式 (9) 可进一步表示为:

$$I(X;Y) = -H(X,Y) + H(X) + H(Y) \quad (10)$$

它们之间的关系如图 2 所示。

由图 2 可以看出, 共信息熵 $I(X, Y)$ 越大则两组数据序列就越相似。如果我们把旋转机械的原始振动信号看做数据序列 X , 而经过小波分析后的包含故障信息频带的重构信号看做数据序列 Y , 那么共信息熵就可以用来评估应用不同的基小波进行信号分析后的重构信号与原始振动信号之间的相似度。通过比较可知, 共信息熵最大的基小波即为最适合提取该类故障特征的基小波。




图 2 两组数据序列的共信息熵、联合熵和香农熵之间的关系

4 特征向量的构建及分类

在改进 LDB 算法的研究中, 我们利用两个不同可区分度量得到了两个最优正交子空间集, 并且选择了两个正交子空间集中重复出现的子空间来构建特征向量。本文, 我们将各个子空间的能量特征来构建特征向量。某子空间的能量可由公式 (11) 计算得到:

$$E_i = \sum_{i=1}^M \alpha_i(i)^2 \quad (11)$$

其中: M 为各个子空间包含的小波包系数的个数, $\alpha_i(i)$ 为小波包系数。这样 t 个重复子空间的能量构成了特征矢量 F :

$$F = [E_1, E_2, \dots, E_t] \quad (12)$$

我们将向量 F 作为特征向量送入支持向量机 (SVM) 对不同类型的故障信号进行分类。

支持向量机是一种通过找到一个最优超平面来区分两类样本的一种线性的学习方法。作为一种监督分类方法, 支持向量机从任一样本中在附近的训练点中寻求最大距离, 以便在测试数据时取得良好的分类性能。由于支持向量机的小样本测试的特点, 适用于区分小数据量的不同状态。而实时故障诊断时,

训练数据通常是有限的。出于这个原因，我们选用支持向量机作为分类器对不同健康状态的旋转机械组件进行诊断。然而，由于支持向量机不能直接应用于多类问题分类，对于多类模式识别问题，SVM 可通过两类问题的组合来实现。通常有两种方法：“一对多”策略，“一对一”策略和 DAGSVM 策略。针对上述算法存在无法识别具体故障的缺点，本文采用改进的算法构建多类故障分类器进行模式分类。该多类方法描述如图 3 所示：对于 K 类样本的训练，训练 $K-1$ 个支持向量机，对于第 1 个支持向量机子分类器，以第 1 类样本为正样本，将第 2, 3, ..., K 类样本作为负的训练样本训练 SVM1，然后去掉第一类样本，在剩余的样本中，以第 2 类样本为正样本，将第 3, 4, ..., K 类样本作为负的训练样本训练 SVM2，以此类推直到第 $K-1$ 个分类器设计完毕。测试时，将样本首先输入第一个分类器，如果输出为“1”则判定样本类别为分类器所对应的类别，测试结束。如果不是，则进入下一个分类器，直到判断出测试样本所属的类别。




图 3 SVM 多类分类方法

5 实验结果与讨论

对于上述算法，我们利用轴承振动信号进行了验证。测试轴承采用 6205-2RS JEM SKF 模型。图 4 为测量不同程度损伤的滚动轴承得到的振动信号。采样频率为 12 000 Hz。




图 4 不同程度损伤的轴承的振动信号

基小波的选取试验中，数据序列 X 为包含 12 000 个点的 0.18 mm 孔洞损伤的轴承振动信号，数据序列 Y 为 X 经 4 层小波包变换得到的节点 $[4, 0]$ 的重构信号，根据公式 (10) 可得到各小波基函数的共信息熵值如表 1 所示。

共信息熵 $I(X; Y)$ 越大，表示应用该基小波进行信号分析后的重构信号与原始转静摩擦信号越相似。从表 1 可以得出，选用 rBio1.3 小波作为基小波计算得出的共信息熵值较

大，因此，最终我们选定了 rBio1.3 小波作为该研究的基小波。

表 1 常用小波基函数的共信息熵

小波基	共信息熵	小波基	共信息熵	小波基	共信息熵
Haar	17.007	Coif5	20.737	Bior2.6	20.802
Db2	20.781	Sym2	20.781	Bior4.4	20.763
Db4	20.740	Sym3	20.783	Bior5.5	20.766
Db6	20.771	Sym4	20.788	Bior6.8	20.773
Db8	20.771	Sym5	20.798	rBio1.3	20.879
Db10	20.762	Sym6	20.760	rBio2.4	20.742
Coif1	20.767	Sym7	20.784	rBio2.6	20.805
Coif2	20.796	Sym8	20.801	rBio4.4	20.760
Coif3	20.778	Bior1.3	16.954	rBio5.5	20.776
Coif4	20.765	Bior2.4	20.771	rBio6.8	20.789




图 5 LDB 子空间示意图

由图 5 可以看出，分别采用可区分度量 D_1 和可区分度量 D_2 ，我们共得到了 30 个 LDB 子空间，其中节点 $[3, 5]$ 、 $[4, 0]$ 、 $[4, 1]$ 、 $[4, 4]$ 、 $[4, 5]$ 、 $[4, 6]$ 、 $[4, 7]$ 、 $[4, 8]$ 、 $[4, 9]$ 、 $[4, 12]$ 、 $[4, 13]$ 、 $[4, 14]$ 、 $[4, 15]$ 既出现在图 5 (a) 中，也出现在图 5 (b) 中。即在 L 类组合的分类中这些重复出现的子空间含有相对较高的差异。也就是说，在这 L 类样本中，这些子空间具有较大的统计距离。因此在试验中，我们选用这些重复出现的子空间作为最终选定的最优子空间来构建特征向量。

在进行分类实验时，首先用 160 组数据（每组数据长度为 1 s，4 类模式各 40 组）训练分类器，正确的分类概率为 100%；然后用 80 组（4 类模式各 20 组）送入训练好的分类器进行测试。分类正确与否的判别准则为：当输出矢量与期望输出矢量完全一致时，为正确识别，否则为错误识别。实验得到的轴承信号识别混淆矩阵如表 2 所示。从表 2 的分析可以看出：在该分类实验中，本文提出的综合机械故障诊断方法对不同程度故障轴承的分类具有较高准确性，其故障识别率高达 96.25%。

表 2 实验结果

目标类别	测试样本数	识别结果				识别率 / (%)	总识别率 / (%)
		健康轴承	0.18 mm 孔洞	0.36 mm 孔洞	0.53 mm 孔洞		
健康轴承	20	20	0	0	0	100	96.25
0.18 mm 孔洞	20	0	18	0	2	90	
0.36 mm 孔洞	20	0	0	19	1	95	
0.53 mm 孔洞	20	0	0	0	20	100	

此外, 实验还比较了该算法不同小波基和不同可区分度量在相同识别特征矢量条件下的故障识别率, 分类器均采用支持向量机。具体实验结果见表 3 和表 4。

表 3 采用不同小波基的识别率

小波基	分类准确率/(%)				总识别率/(%)
	健康轴承	0.18 mm 孔洞	0.36 mm 孔洞	0.53 mm 孔洞	
Bior5.5	100	95	85	100	95.00
Db10	100	90	85	100	93.75
rBio1.3	100	90	95	100	96.25

表 4 采用不同可区分度量方法的识别率

可区分度量	总识别率/(%)
D_1	93.75
D_2	93.75
$D_1 \& D_2$	96.25

从表 3 中可以看出, 使用 rBio1.3 小波即本实验中最适合该型号轴承信号的分析小波作为基小波的方法比使用其他小波基函数时获得了更高的分类准确率。另一方面, 表 4 的结果表明, 采用结合两种可区分度量的方法相比采用单一可区分度量的方法提高了分类准确性。该结果表明, 本文提出的定量小波选取和改进 LDB 算法结合的方法对复杂多类问题的分类具有良好的分析效果。

6 结论

本文通过对实际采集的不同故障类型下的轴承振动信号的分析结果表明, 采用定量小波选取和改进局域判别基算法的故障诊断方法可以有效识别滚动轴承的故障类型。此外, 从两个对照实验的实验结果可知, 分别使用定量基小波选取和多种可区分度量的改进 LDB 算法均提高了分类的准确率, 体现了定量小波基选取和多种可区分度量的改进 LDB 算法的有效性。

(上接第 2390 页)

参考文献:

[1] Deb S, Pattipati K R, Raghavan V, et al. Multi-signal flow graphs: a Novel approach for system testability analysis and fault diagnosis [A]. Proc. IEEE AUTOTESTCON [C]. 1994: 361-373.

[2] Tu F, Pattipati K R. Rollout strategies for sequential fault diagnosis [J]. IEEE Transactions on Systems, Man, and Cybernetics, 2003, 33 (1): 86-99.

[3] Pattipati K R, Alexandridis M G. Application of Heuristic Search an Information Theory to Sequential Fault Diagnosis [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1990, 20 (4): 872-886.

[4] 高 磊, 吕振中, 景小宁. 飞机实时测试序列生成算法研究及仿真 [J]. 计算机工程与应用, 2006, (9): 228-232.

[5] 石君友, 田 仲. 故障诊断策略的优化方法 [J]. 航空学报, 2003, 24 (3): 212-215.

[6] 陈刚勇. 复杂系统分层诊断策略优化技术研究 [D]. 长沙: 国防科技大学, 2008.

参考文献:

[1] 王移芝, 罗四维. 大学计算机基础教程 [M]. 北京: 高等教育出版社, 2004.

[2] Marwa C, Mohamad K, Jacques D. Methodology of wavelet packet selection for event detection [J]. Signal Processing, 2006, 86 (16): 3826.

[3] Wu Y, Du R. Feature extraction and assessment using wavelet packets for monitoring of machining processes [J]. Mechanical System and Signal Process, 1996, 10 (1): 29-53.

[4] 冯登国. 计算机通信网络安全 [M]. 北京: 清华大学出版社, 2007.

[5] 孙凤宏. 探索未来计算机技术发展与应用 [J]. 青海统计, 2007, (11).

[6] He Q, Yan R, Gao R. Wavelet packet base selection for gearbox defect severity classification [A]. Prognostics and System Health Management Conference [C]. Macao, 2010.

[7] Wu Y H, Shan M X, Qian Y N, et al. Aeroengine rub-impact fault diagnosis based on wavelet packet transform and the local discriminate bases [J]. Applied Mechanics and Materials, 2012, 216-228: 740-744.

[8] Umopathy K, Krishnan S, Rao R K. Audio signal feature extraction and classification using local discriminant bases [J]. Speech & Language Processing, 2007, 15: 1236-1246.

[9] Incea N F, Tewfik A H, Arica S. Extraction subject-specific motor imagery time-frequency patterns for single trial EEG classification [J]. Computers in Biology and Medicine, 2007, 37: 499-508.

[10] Wang G, Wang Z Z, Chen W T, et al. Classification of surface EMG signals using optimal wavelet packet method based on Davies-Bouldin criterion [J]. Med. Bio. Eng. Comput., 2006, 44: 865-872.

[11] Yen G G, Leong W F. Fault classification on vibration data with wavelet based feature selection scheme [J]. ISA Transactions, 2006, 45: 141-151.

[7] 李 丽, 牛 奔. 粒子群优化算法 [M]. 北京: 冶金工业出版社, 2009.

[8] Kennedy J, Eberhart R C. Particle swarm optimization [A]. Proceedings of the IEEE International Joint Conference on Neural Networks [C]. Piscataway, NJ: IEEE Service Center, IEEE Press, 1995: 1942-1948.

[9] Shi Y, Eberhart R C. A modified particle swarm optimizer [A]. Proceedings of the IEEE World Congress on Computational Intelligence [C]. 1998: 69-73.

[10] Rameshkumar K, Suresh R K, Mohanasundaram K M. Discrete particle swarm optimization (DPSO) algorithm for permutation flowshop scheduling to minimize makspan [A]. Proc. ICNC 2005, LNCS 3612 [C], 2005: 572-581.

[11] 张长胜, 孙吉贵, 欧阳丹彤. 一种自适应离散粒子群算法及其应用研究 [J]. 电子学报, 2009, 37 (2): 299-303.

[12] Johnson R A. An information theory approach to diagnosis [A]. Proceedings of the 6th Annual Conference on Reliability and Quality Control [C], 1960: 102.