

基于声音信号的结构损伤识别方法*

瞿金秀¹, 杨飞宇¹, 张周锁¹, 何正嘉²

(1. 西安交通大学机械工程学院 西安, 710049)

(2. 西安交通大学机械制造系统工程国家重点实验室 西安, 710049)

摘要 随着对设备可靠性要求的提高,在生产过程中需要对关键设备的重要零部件在主要工序之后全部进行结构损伤检测,在服役过程中需要对关键设备重要零部件定期在线进行无损检测。为了克服现有的结构损伤检测方法的不足,满足工程实际的迫切需要,利用基于声音信号的结构损伤检测具有非接触测量、高效、可在线检测等优点,构建了一种基于声音信号的结构损伤识别模型。该模型的核心包括信号降噪、特征提取、基于距离评估的损伤敏感特征选择以及基于支持向量机的状态识别。将该模型应用于实验悬臂梁和铁路转辙机动作杆的裂纹损伤识别,结果表明,识别准确率均为 100%,且识别过程仅需几秒,验证了该模型的有效性和可行性。

关键词 声音信号; 结构损伤识别; 特征提取; 敏感特征选择; 支持向量机

中图分类号 TH136

引言

随着对关键设备可靠性要求的提高,在生产过程中需要对关键设备的重要零部件在主要工序之后全部进行结构损伤检测。在关键设备服役过程中,需要对其重要零部件定期在线进行结构损伤检测。现在普遍使用磁粉法、渗透法和超声波检测等损伤检测方法,由于效率低,这些方法只能进行抽检,难以实现全检。可见,方便、高效的结构损伤检测技术是工程实际的迫切需要。声音信号具有非接触测量、采集方便和处理速度快等特点。从本质上来说,声音与振动信号类似,是反映机器零件损伤状态的重要信息来源^[1]。目前,铁路机务工在车站检查列车时仍通过敲击车轴、倾听其声音来判别车轴是否出现损伤。这种方法需要长期的经验积累,容易误判且难以实现通用化。随着计算机、信号处理、智能识别等技术的发展,使得基于声音信号的结构损伤识别有望实现智能化和通用化,满足工业现场方便、高效、准确的要求。声音信号分析方法开始于 20 世纪 80 年代中期,在 90 年代发展较快,目前已在许多领域应用。Philippe 等^[2]应用非线性声学特征和参数有效地检测评估了材料早期损伤状态。周艳玲等^[3]利用小波分解的方法提取了轴承故障的声音信

号特征,有效诊断出设备故障。吴峰崎等^[4]通过提取声音信号的三维谱特征,对转子进行了故障诊断。利用声音信号对机器零件结构进行损伤识别目前还少有人涉及。

笔者研究了声音信号的降噪、特征提取、基于距离评估的损伤敏感特征选择以及基于支持向量机(support vector machine,简称 SVM)的状态识别,构建了相应的结构损伤识别模型,并将该模型应用于实验悬臂梁和铁路转辙机动作杆的裂纹损伤识别,验证了其可行性和有效性。

1 声音信号的降噪

1.1 去除背景噪声

由于构建的结构损伤识别模型需要应用在生产 and 应用现场,这就无法避免声音信号在采集过程中受到外界背景噪声的影响。采集的数据一旦被背景噪声干扰,将导致损伤特征提取困难,从而影响检测效果。因此,如何从复杂的背景噪声中提取有用信号,是对声音信号进行预处理必须解决的问题。笔者采取以下步骤去除声音信号的背景噪声:a. 直接采集实验室和工厂中的背景噪声和结构的聲音信

* 国家自然科学基金资助项目(51275382,11176024)

收稿日期:2012-06-26;修回日期:2012-09-20

号,对其频谱图作比较;b.通过比较分析,找寻背景噪声在频域内能量分布最集中的频带;c.将采集到的声音信号在上述频带内的数据置零,重构信号。

1.2 基于邻域相关性的冗余第2代小波降噪

传统小波阈值降噪方法没有考虑小波系数之间的相关性,且传统小波分解时通过抽样得到小波系数,这可能会使不同尺度信号特征因为抽样位置不同而发生变换。为此,笔者采用基于邻域相关性的冗余第2代小波降噪方法^[5]。

假定 $\bar{d}_{j-1}^{(k)}$, $\bar{d}_j^{(k)}$ 和 $\bar{d}_{j+1}^{(k)}$ 分别为信号进行冗余第2代小波分解后第 k 层细节信号的第 $j-1$, j 和 $j+1$ 个样本。经过阈值处理后,细节信号可以表示为

$$\hat{d}_i^{(k)} = \begin{cases} \bar{d}_i^{(k)} \left(1 - \frac{\alpha_k^2}{M_{k,i}^2}\right) & (M_{k,i}^2 \geq (\alpha_k)^2) \\ 0 & (M_{k,i}^2 < (\alpha_k)^2) \end{cases} \quad (1)$$

$$M_{k,i}^2 = (\bar{d}_{i-1}^{(k)})^2 + (\bar{d}_i^{(k)})^2 + (\bar{d}_{i+1}^{(k)})^2$$

$$\alpha_k = \sqrt{2\sigma_k^2 \ln(L)}$$

其中: k 为小波分解层数; L 为含噪信号的长度; σ_k 为第 k 层噪声的标准差。

基于邻域相关性的冗余第2代小波降噪方法的具体步骤为:a.利用冗余第2代小波对含噪信号进行分解,计算分解后每层的细节信号;b.计算分解后每层的参数 $M_{k,i}^2$ 和 α_k ;c.利用式(1)对细节信号进行阈值化处理;d.通过小波逆变换重构信号,得到降噪后的信号。

2 声音信号的特征提取

由于声音信号为非平稳信号,且易受环境干扰,信噪比低,构成复杂,因此必须通过有效的特征提取方法,将可能反映损伤的特征参数提取出来,为敏感特征选择和状态识别提供丰富的特征信息。笔者从以下4个方面提取损伤特征信息。

2.1 模态特征

模态参数反映结构的振动特性,当结构发生损伤时,其模态参数将会发生变化。通过声音信号对结构的模态特征(固有频率、阻尼比等)进行提取,可以更好地凸显结构的固有特性。

由于从脉冲激励产生的声音信号中很难得到三阶以后固有频率和阻尼比的准确解,因此这里提取前三阶固有频率和阻尼比作为结构损伤检测的模态特征。

2.2 时域特征

相对于如均值、方差和均方根值等时域有量纲指标,无量纲指标具有对信号频率和幅值变化都不敏感的特点,它们基本不受外部因素的影响。此外,它们不受信号绝对水平的影响,即使测点略有变化,也不至于对损伤检测结果产生太大的影响。

笔者选择6个时域无量纲指标($T_1 \sim T_6$)作为结构损伤检测的时域特征,如表1所示,其中, σ 和 \bar{x} 分别为信号 $x(n)$ 的标准差和均值。

2.3 频域特征

当结构出现损伤时,信号中的频率成分、不同频率成分的能量以及频谱的主能量谱峰位置也将发生变化。通过描述信号频谱中能量的大小和分布等可以反映声音信号的频域信息,从而指示损伤的出现。但是,原始声音信号的频带较宽,结构的损伤特征频率成分有时表现的不够明显。为了能够清楚地反映损伤特征信息,笔者采用谐波小波,选择原始信号能量集中的频带对信号进行滤波处理,提取每一个滤波频带的13个频域特征($F_1 \sim F_{13}$),如表1所示。其中: F_1 反映频谱振动能量的大小; $F_2 \sim F_4$, F_6 和 $F_{10} \sim F_{13}$ 表征频谱的分散或者集中程度; F_5 和 $F_7 \sim F_9$ 反映主频带位置的变化。

2.4 小波包能量特征

小波包技术将信号无冗余、无疏漏、正交地分解到独立的频带内,这些分解频带信号都具有一定的能量^[6]。每个频带里信号的能量对于结构损伤识别是十分有用的信息;但是,小波包能量是有量纲参数,容易受到外部实验条件的干扰,无法准确反映声音信号的能量分布。为此,笔者将单个频带的能量大小与所有频带能量总和之比作为小波包能量特征。首先,对采集到的声音信号进行4尺度的二代小波包分解和重构,得到从低频到高频相互衔接的16个频带;然后,按照下式分别计算各个频带的能量指标

$$\rho_j = \frac{E(j)}{\sum_{j=1}^{16} E(j)} \quad (2)$$

其中: $E(j) = \sum_{i=1}^n (x(i))^2$; $x(i)$ 为信号离散点幅值; $i=1, 2, \dots, n$, 为重构后信号的离散点个数; $j=1, 2, \dots, 16$, 为频带序号。

表1 特征参数

Tab. 1 The feature parameters

$T_1 = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N x(n)^2}}{\frac{1}{N} \sum_{n=1}^N x(n) }$	$T_2 = \frac{\max x(n) }{\sqrt{\frac{1}{N} \sum_{n=1}^N x(n)^2}}$	$T_3 = \frac{\max x(n) }{\frac{1}{N} \sum_{n=1}^N x(n) }$	$T_4 = \frac{\max x(n) }{(\frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) })^2}$
$T_5 = \frac{\sum_{n=1}^N (x(n) - \bar{x})^4}{(N-1)\sigma^4}$	$T_6 = \frac{\sum_{n=1}^N (x(n) - \bar{x})^3}{(N-1)\sigma^3}$	$F_1 = \frac{\sum_{k=1}^K s(k)}{K}$	$F_2 = \frac{\sum_{k=1}^K (s(k) - F_1)^2}{K-1}$
$F_3 = \frac{\sum_{k=1}^K (s(k) - F_1)^3}{K(\sqrt{F_2})^3}$	$F_4 = \frac{\sum_{k=1}^K (s(k) - F_1)^4}{KF_2^2}$	$F_5 = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$	$F_6 = \sqrt{\frac{\sum_{k=1}^K (f_k - F_5)^2 s(k)}{K}}$
$F_7 = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$	$F_8 = \sqrt{\frac{\sum_{k=1}^K f_k^4 s(k)}{\sum_{k=1}^K f_k^2 s(k)}}$	$F_9 = \frac{\sum_{k=1}^K f_k^2 s(k)}{\sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k s(k)}}$	$F_{10} = \frac{F_6}{F_5}$
$F_{11} = \frac{\sum_{k=1}^K (f_k - F_5)^3 s(k)}{KF_6^3}$	$F_{12} = \frac{\sum_{k=1}^K (f_k - F_5)^4 s(k)}{KF_6^4}$	$F_{13} = \frac{\sum_{k=1}^K (f_k - F_5)^{\frac{1}{2}} s(k)}{K \sqrt{F_6}}$	

$x(n)$ 为时域信号序列, $n=1,2,\dots,N$; N 为数据点数; $s(k)$ 为信号 $x(n)$ 的频谱, $k=1,2,\dots,K$; K 为谱线数; f_k 为第 k 条谱线的频率值

3 基于距离评估的敏感特征选择

以上提取的原始特征中,一部分与损伤紧密相关,另一部分则是无关或是冗余特征。因此,在输入到分类器之前,须要将与损伤密切相关的敏感特征选择出来,剔除其他不相关的特征以提高识别的准确率,降低分类器的计算负担。笔者采用基于距离的特征评估技术^[7]来选择敏感特征。

基于距离的特征评估技术根据特征间距离大小判断特征的敏感度。对不同的特征,同一类样本的类内距离越小,不同类样本的类间距离越大,则特征越敏感。具体步骤如下。

1) 计算第 c 类第 j 个特征的类内距离

$$d_{c,j} = \frac{1}{M_c(M_c - 1)} \sum_{l,m=1}^{M_c} |q_{m,c,j} - q_{l,c,j}| \quad (3)$$

($l, m = 1, 2, \dots, M_c; l \neq m; j = 1, 2, \dots, J; c = 1, 2, \dots, C$)

其中: M_c 为第 c 类的样本个数; J 为特征个数; C 为类别个数; $q_{m,c,j}, q_{l,c,j}$ 分别为第 c 类第 m 个和第 l 个样本的第 j 个特征的特征值。

计算第 j 个特征 C 个类的类内距离的平均值

$$d_j^{(w)} = \frac{1}{C} \sum_{c=1}^C d_{c,j} \quad (4)$$

2) 计算第 c 类 M_c 个样本第 j 个特征的平均值

$$u_{c,j} = \frac{1}{M_c} \sum_{m=1}^{M_c} q_{m,c,j} \quad (5)$$

计算第 j 个特征 C 个类的类间距离的平均值

$$d_j^{(b)} = \frac{1}{C(C-1)} \sum_{c,e=1}^C |u_{e,j} - u_{c,j}| \quad (6)$$

($c, e = 1, 2, \dots, C; c \neq e$)

3) 计算第 j 个特征的评估因子

$$\alpha_j = \frac{d_j^{(b)}}{d_j^{(w)}} \quad (7)$$

α_j 的大小反映了第 j 个特征对 C 个类进行分类的难易程度。 α_j 越大,表示第 j 个特征越敏感,更容易对 C 个类进行分类。

4) 敏感特征集的确定

按照 α_j 值从大到小的顺序对特征排序,并逐一增加特征个数,输入后续分类器进行训练和测试。在识别率最高的前提下,选择对应数目最少的输入特征组成敏感特征集。

4 结构损伤识别模型

结构损伤识别模型如图1所示,除了信号降噪,特征提取和基于距离评估的敏感特征选择外,它还主要包括基于SVM的状态识别^[8-9],具体步骤为:

a. 选择训练样本,将敏感特征集作为SVM的输入;
b. 初始化SVM的参数(核函数、核函数参数 p 以及惩罚因子 C 等),训练SVM模型;
c. 选择测试样本,测试SVM模型;
d. 以测试准确率为优化目标,用遗传模拟退火优化算法对SVM的参数进行优化;
e. 以优化参数作为模型参数,建立基于SVM的结构损伤识别模型。

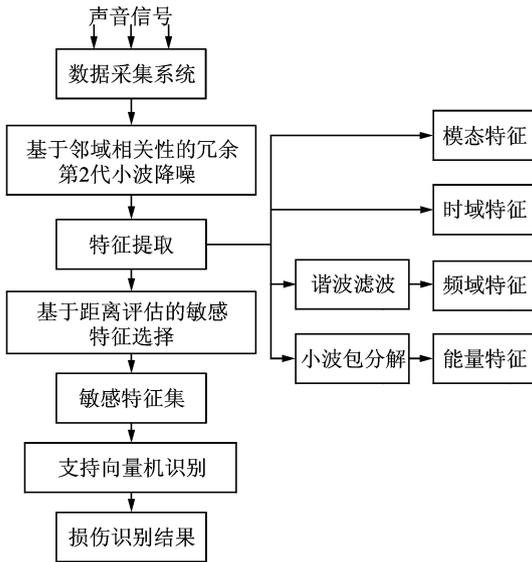


图 1 损伤识别模型

Fig. 1 The model of damage identification

5 实验验证及工程应用

5.1 实验验证

实验对象为 3 根裂纹梁试件和 2 根正常梁试件,悬臂梁的参数为:宽度 $B=20\text{ mm}$,高度 $H=12\text{ mm}$,长 $L=515\text{ mm}$,材料为 45# 钢。损伤裂纹通过线切割机切割而成,宽度为 0.2 mm 。裂纹工况描述、实验裂纹梁和实验装置分别如表 2、图 2、3 所示。

表 2 裂纹工况描述

Tab. 2 Description of the crack conditions

裂纹工况	裂纹距离固定端的距离/ mm	裂纹深度/ mm
1	85	4
2	100	4
3	420	4



图 2 实验裂纹梁

Fig. 2 Experimental crack beam

5.1.1 信号采集与特征提取

声音传感器采用 MP201 型号的传声器,并将其布置在距声源大约 0.5 m 处,激励点选在距固定端

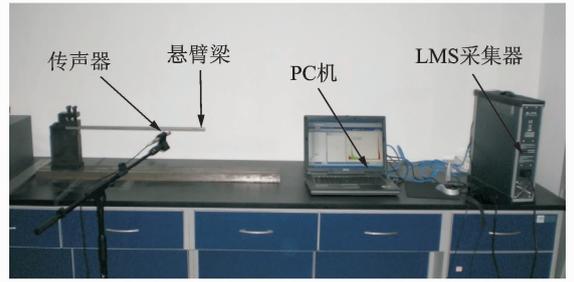
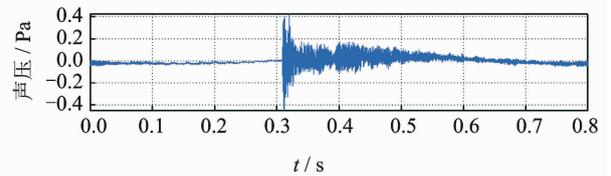


图 3 实验装置

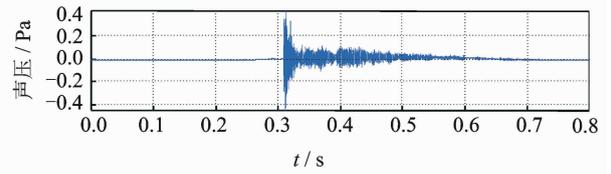
Fig. 3 Experimental device

130 mm 处。采用脉冲激励法,以 $40\ 960\text{ Hz}$ 的采样频率分别采集了 42 组正常样本、33 组工况 1 样本、35 组工况 2 样本和 33 组工况 3 样本。降噪前和降噪后的声音信号如图 4 所示,对比发现,降噪后信号的信噪比得到了明显提高。



(a) 降噪前时域波形

(a) Time domain waveform before noise reduction



(b) 降噪后时域波形

(b) Time domain waveform after noise reduction

图 4 降噪前后声音信号的时域波形图

Fig. 4 Time domain waveforms before and after noise reduction

首先,采用谐波小波将降噪后的信号能量分布最集中的 6 个频段进行滤波,分别求出每个频段的 13 个频域特征,共计 78 个;然后,分别提取 6 个无量纲时域特征、16 个小波包能量指标、3 阶固有频率和 3 阶阻尼比特征。原始特征集中共包含 106 个特征。

5.1.2 特征选择

对提取的 106 个特征进行敏感度评估,其敏感度大小如图 5 所示。为了使选择的敏感特征在分类时具有一定的通用性,初始敏感特征数设置为 5 个。选择 32 个正常样本和第 1,2 类有损伤样本为训练样本,10 个正常样本和第 3 类有损伤样本为测试样

本。按照评估因子由大到小的顺序,把 SVM 输入特征的个数从 5 逐渐增加到 106 个,对其进行训练和测试,得到的输入特征个数与检测准确率的关系曲线如图 6 所示。可以看出,当输入特征个数位于区间 $[16,30]$ 时,检测准确率一直保持在 100%。因此,选择前 16 个特征作为敏感特征集,既可以有效地将有损伤悬臂梁分离开来,又可以减少分类器的计算量。它们位于图 5 中的水平线之上,水平线的高度对应第 16 个敏感特征评估因子 α_{16} 的大小 ($\alpha_{16}=0.7681$)。这 16 个敏感特征分别为前三阶固有频率,频域特征中第 1 频段的 F_8 、第 3 频段的 F_3 、第 5 频段的 F_8 和第 6 频段 $F_1, F_2, F_4, F_8, F_9, F_{13}$ 以及第 1, 2, 3, 7 个频带的小波包能量特征。

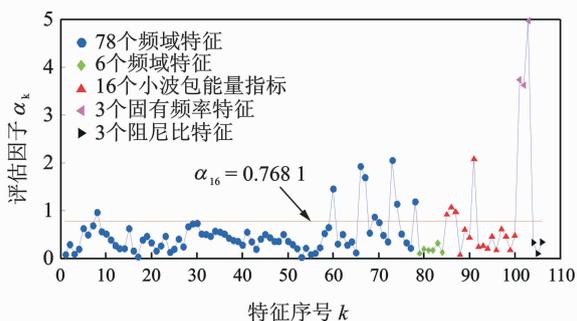


图 5 所有特征的评估因子

Fig. 5 Distance evaluation factors of all the features

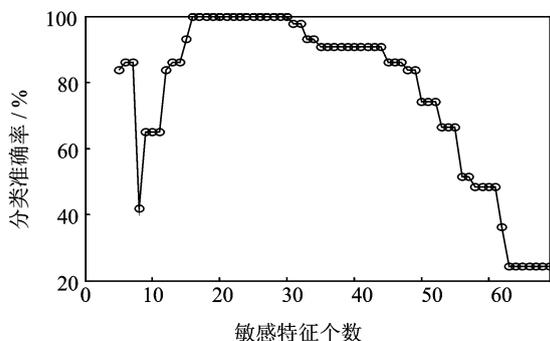


图 6 输入特征个数与检测准确率之间的关系

Fig. 6 Testing accuracy varying with input features

5.1.3 构建识别模型

以 32 组正常样本和第 1, 2 类有损伤样本为训练样本,10 组正常样本和第 3 类有损伤样本为测试样本,用遗传模拟退火算法优化后的 SVM 参数为:核函数为径向基函数,惩罚因子 C 为 9 579,核函数参数 p 为 157.96。

5.1.4 测试与分析

以 10 组正常样本和第 3 类有损伤样本为测试样本,对模型进行测试,最终得到的识别正确率为

100%。虽然选择的训练样本与测试样本来源于不同的对象,但是仍然取得了很好的识别效果。这说明该方法具有可行性和一定的通用性。

5.2 工程应用

转辙机通过动作杆实现牵引道岔移动,如果动作杆损伤断裂,则道岔无法转换,影响行车安全。应用对象为某铁路信号工厂生产的 1 根有损伤和 1 根正常的转辙机动作杆,其结构的损伤是在加工过程中产生的自然裂纹。动作杆的外形和损伤部位分别如图 7, 8 所示。



图 7 动作杆外形

Fig. 7 The shape of traction pole



图 8 损伤动作杆

Fig. 8 The damaged traction pole

5.2.1 信号采集和特征提取

实验装置和悬臂梁实验装置一样,动作杆的固定方式为悬挂式,选择离悬挂点 50 mm 处为激励点,同样以力锤激励和以 40 960 Hz 为采样频率。分别采集了 40 组正常样本和 40 组有损伤动样本。首先,对声音信号进行降噪处理;然后,采用谐波小波将降噪后的信号能量分布最集中的 10 个频段进行滤波,分别求出每个频段的 13 个频域特征,共计 130 个;最后,分别提取 6 个无量纲时域特征,16 个小波包能量指标,3 阶固有频率和 3 阶阻尼比特征。原始特征集中共包含 158 个特征。

5.2.2 特征选择

首先,采用距离度量的方法对所有特征进行敏感度评估;然后,按照评估因子由大到小的顺序对特征排序,选取前 5 个特征作为初始的敏感特征集,取前 30 个正常样本和前 30 个有损伤样本作为训练样本,按照评估因子由大到小的顺序,把 SVM 输入特征的个数从 5 逐渐增加到 158 个,对其进行训练和测试。最终选择出 5 个特征敏感特征,选择出的 5 个敏感特征分别为:前三阶固有频率、第 8 个频段的指标 F_1 和第 4 个频段的指标 F_4 。

5.2.3 构建识别模型

以30组正常样本和30组有损伤样本为训练样本,10个正常样本和10个有损伤样本为测试样本。用遗传模拟退火算法优化后的SVM参数为:核函数为径向基函数,惩罚因子 C 为8 159.3,核函数参数 p 为838.81。

5.2.4 测试与分析

以10个正常样本和10个有损伤样本为测试样本对模型进行测试,得到的识别正确率为100%,说明该方法具有可行性。由于动作杆数量有限,训练样本和测试样本来源于同一对象,容易判别。因此,虽然分类结果很好,但是该模型的通用性还需要在更多的应用对象上进一步验证。

6 结 论

1) 利用多种信号预处理方法挖掘隐藏在声音信号中的损伤信息,综合利用从不同侧面表征结构损伤状态的时域、频域和能量特征构成原始特征集,能够准确、全面地获得损伤特征信息。

2) 基于距离评估的敏感特征选择方法能够从大量的原始特征集中选择出敏感特征,删除不相关特征,从而提高损伤识别的准确率,降低分类器的计算负担。

3) 将该模型应用于实验悬臂梁和生产现场中铁路转辙机动作杆的裂纹损伤识别,识别准确率均达到了100%,且识别效率高。这验证了该模型的有效性和可行性,为结构损伤识别提供了一种新的途径。其中,悬臂梁结构的训练样本和测试样本来源于不同的对象,结果表明该模型可以准确识别不同部位的损伤。由于动作杆数量有限,其训练样本和测试样本来源于同一个对象,虽然识别效果好,但是该模型的通用性还需要在更多的应用对象上进一步验证。

参 考 文 献

- [1] 屈梁生,何正嘉. 机械故障诊断学[M]. 上海:上海科学技术出版社,1986:112-121.
- [2] Philippe D, Marco M, Peter C. A study of the vibro-acoustic modulation technique for the detection of cracks in metals[J]. The Journal of the Acoustical Society, 2006,119(3):1463-1475.
- [3] 周艳玲,杨德斌,徐金梧,等. 基于声信号的轴承故障诊断方法[J]. 振动与冲击,2002,21(2):21-23.
Zhou Yanling, Yang Debin, Xu Jinwu, et al. The bearing fault diagnosis method based on sound signal

[J]. Journal of Vibration and Shock, 2002, 21(2): 21-23. (in Chinese)

- [4] 吴峰崎,孟光,荆建平. 基于声信号三维谱分析的转子复合碰摩故障特征提取[J]. 振动与冲击,2005,24(6):79-84.
Wu Fengqi, Meng Guang, Jing Jianping. The rotor compound rubbing fault feature extraction based on three-dimensional spectral analysis of acoustic signal [J]. Journal of Vibration and Shock, 2005, 24(6): 79-84. (in Chinese)
- [5] 李臻. 第二代小波理论及其在故障诊断中的应用研究[D]. 西安:西安交通大学,2008.
- [6] 王计生,喻俊馨,黄惟公. 小波包分析和支持向量机在刀具故障诊断中的应用[J]. 振动、测试与诊断,2008,28(3):273-276.
Wang Jisheng, Yu Junxin, Huang Weigong. The application wavelet packet analysis and support vector machine in tool fault diagnosis[J]. Journal of Vibration, Measurement & Diagnosis, 2008, 28(3): 273-276. (in Chinese)
- [7] Lei Yaguo, He Zhengjia, Zi Yanyang. Application of an intelligent classification method to mechanical fault diagnosis [J]. Expert Systems with Applications, 2009, 36(6): 9941-9948.
- [8] 刘永斌,何清波,孔凡让,等. 基于PCA和SVM的内燃机故障诊断[J]. 振动、测试与诊断,2012,32(2):250-255.
Liu Yongbin, He Qingbo, Kong Fanrang, et al. Fault diagnosis of internal combustion engine using PCA and SVM[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 250-255. (in Chinese)
- [9] Widodo A, Yang B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.



第一作者简介:瞿金秀,女,1988年6月生,博士研究生。主要研究方向为机械信号处理、机械故障智能诊断。曾发表《基于多小波包和邻域粗糙集的故障诊断模型》(《振动、测试与诊断》2013年第33卷第S1期)等论文。
E-mail: ytuqjx@163.com

通信作者简介:张周锁,男,1964年9月生,教授、博士生导师。主要研究方向为机械状态监测、机械故障智能诊断与预示和机械动态分析。
E-mail: zzs@mail. xjtu. edu. cn