

多振动信号的时频相干多分形特征提取^{*}

任海锋, 潘宏侠

(中北大学机械工程学院 太原, 030051)

摘要 为充分利用多个同步采样的振动信号进行机械设备的故障诊断,提出了搭建多振动信号时频相干网络并提取其多分形特征的方法。首先,将每个振动信号作为一个节点,根据所关心的物理问题,按适当的方式将各个节点连接成网;其次,对网络中相邻的每对节点做交叉小波变换,得到时频相干谱,借助小波领袖来估计时频相干谱的多分形谱,用曲线拟合的方法来提取多分形谱的形态特征;最后,利用特征融合与维数约简方法,对已得到的所有特征进行融合和降维,从而得到整个网络的最终特征。该方法给出了一个提取多振动信号时频相干多分形特征的框架,并在某高射机枪自动机的裂纹故障诊断中取得了成功应用,具有广泛的适用范围。

关键词 故障诊断;时频分析;特征提取;数据级融合;振动;相干;多分形

中图分类号 TH165.3;TH113.1;TN911.6

引言

振动信号在机械设备故障诊断中得到了广泛应用。在实际的振动测试中,通常会得到多个同步采样的振动信号。这是因为三向的振动加速度传感器很常见,它们的布置安装也相对容易,而且通过数字信号采集仪可以很方便地实现多个数据通道的同步采样。如何更加充分地利用这些同步采样的振动信号,是机械故障诊断中的重要研究课题。

多振动信号的综合利用可视为一个信息融合问题。信息融合可从两个不同的角度分为 3 个层次和 5 种模式^[1]。根据所融合的信息层次的不同,可将信息融合分为数据级融合、特征级融合和决策级融合。根据输入输出信息类型的不同,可得到信息融合的 5 种模式:输入数据-输出数据、输入数据-输出特征、输入特征-输出特征、输入特征-输出决策以及输入决策-输出决策。一个信息融合的实际应用,可能会包含以上的全部层次和模式,也可能只涉及其中的一部分。笔者主要关注数据级融合与初始特征的提取问题,主要涉及输入数据-输出数据和输入数据-输出特征两种模式。本研究要解决的主要问题是:以何种方式来组织多个同步采样的振动信号,以使它们之间产生某种形式的联系,以及以何种手段来提取这些联系的特征。

文献[2-3]提出了二维全息谱、三维全息谱、全息动平衡法等一系列全息技术并将其应用于旋转机械的故障诊断中,实现了同步测试的一个或多个测量截面上两个相互垂直方向上的位移振动信号的数据级融合与特征提取。与之类似的是矢谱类方法^[4-5]。谷立臣等^[6]利用神经网络,从含有观测噪声的多传感器信号中估计出使观测数据均方误差最小的数据融合权值,实现了多传感器信号的数据级融合。李毓辉等^[7]利用旋转机械振动信号的循环平稳特性,采用基于二阶统计量的盲均衡技术,实现了多个振动信号的数据级融合。Bin 等^[8]通过振动信号间的互相关函数来得到各个振动信号的加权值,并用这些加权值对振动信号进行线性组合,从而实现了多振动信号的数据级融合。李火坤等^[9]根据坝体结构振动响应信号的特点,提出了基于方差贡献率的多振动信号数据级融合方法,并将其应用于高拱坝的泄洪振动监测中。王江萍等^[10]将属于不同测点的两个振动信号的功率谱密度函数比值的平方根作为特征向量,实现了振动信号的数据级融合,并应用于柴油机的故障诊断。此外,还有一些关于多传感器数据融合的一般理论和方法的讨论^[11-12]。

然而,这些研究要么是针对某种类型的具体问题,不具有广泛的适用性;要么是只考虑了信号本身的特征,而缺少对被测系统物理特性的利用。笔者提出结合物理系统的结构和动力学特性来搭建多振

^{*} 国家自然科学基金资助项目(51675491)
收稿日期:2017-11-24;修回日期:2018-05-22

动信号的时频相干网络并提取其多分形特征的方法,以给出一个有效且适用范围广的多振动信号特征提取框架。此方法已成功应用于某高射机枪闭锁机构的裂纹故障诊断。

1 方 法

本研究中的信号限定为同步采样的多个振动信号,即采样频率与采样起始时刻均相同的等间隔采样振动信号。笔者将每个这样的信号视为一个节点,通过搭建时频相干网络来建立信号间的联系,并提取这些联系的多分形特征。其中两个相邻节点间的时频相干特性通过交叉小波变换来获得,而每个时频相干谱的多分形特征,则通过小波领袖和曲线拟合的方法来提取。图 1 给出了此方法的处理流程,由于本研究旨在给出一个具有通用性的方法框架,故对于其中的某些步骤并不限定必须使用的特定方法,在实际应用中可以根据具体问题来适当选取。

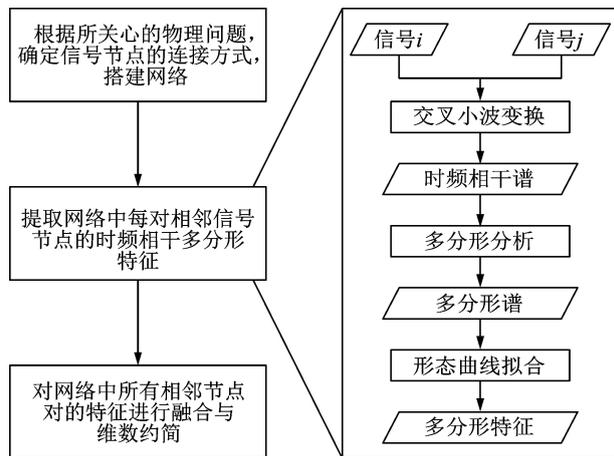


图 1 多振动信号时频相干多分形特征的提取流程

Fig. 1 The extraction process of time-frequency coherence multifractal features of multiple vibration signals

1.1 交叉小波变换与时频相干谱

设 X 和 Y 是两个时间序列,它们的连续小波变换分别为 $W_n^X(s)$ 和 $W_n^Y(s)$,则 X 与 Y 的交叉小波变换定义^[13-14]为

$$W_n^{XY}(s) = W_n^X(s)W_n^{Y*}(s) \quad (1)$$

其中: n 为平移指标; s 为伸缩系数; $W_n^{Y*}(s)$ 为 $W_n^Y(s)$ 的复数共轭; $W_n^{XY}(s)$ 为由 n 和 s 两个变量张成的一个离散的二维谱,称为交叉小波谱,一般来说, $W_n^{XY}(s)$ 的值为复数。

时间序列 X 和 Y 的相干系数谱 $R_n^{XY}(s)$ 定义为

$$R_n^{XY}(s) = \sqrt{\frac{|S(s^{-1}W_n^{XY}(s))|^2}{S(s^{-1}|W_n^X(s)|^2)S(s^{-1}|W_n^Y(s)|^2)}} \quad (2)$$

其中: S 为一个平滑函数。

S 对 $W_n^{XY}(s)$ 的作用可写为

$$S(W_n^{XY}(s)) = S_{\text{scale}}(S_{\text{time}}(W_n^{XY}(s))) \quad (3)$$

其中: S_{time} 和 S_{scale} 分别为沿时间和尺度两个方向的平滑函数。

应选用适当形式的 S ,使相干系数 $R_n^{XY}(s)$ 具有尺度不变性,更具体的讨论见文献[15]。

$R_n^{XY}(s)$ 的定义与传统的互相关系数 r^{XY} 的定义类似,所不同的是, r^{XY} 为一个标量,而 $R_n^{XY}(s)$ 则是一个关于 n 和 s 的二维谱,是 r^{XY} 在尺度-时间平面内的扩展,可以反映时间序列 X 和 Y 在此平面内每一点处的互相关程度。 $R_n^{XY}(s)$ 是在区间 $[0,1]$ 内取值的实值谱,它的值不受 X 和 Y 的数量级的影响。

进行交叉小波变换的两个时间序列要有相同的数据点数,并且都是等间隔的采样数据。可见,同步采样的振动信号满足这些要求。在进行各自的连续小波变换时, X 和 Y 还要使用相同的小波函数和相同的伸缩系数序列 $\{s_i\}$ 。交叉小波谱 $W_n^{XY}(s)$ 和相干系数谱 $R_n^{XY}(s)$ 是时频相干谱的两种不同形式。

1.2 时频相干网络的搭建

由复数的运算规则可知

$$W_n^X(s)W_n^{Y*}(s) = (W_n^Y(s)W_n^{X*}(s))^* \quad (4)$$

故有

$$W_n^{XY}(s) = (W_n^{YX}(s))^* \quad (5)$$

即 $W_n^{XY}(s)$ 关于 X 和 Y 具有共轭对称性。同理,由 $R_n^{XY}(s)$ 的定义可知, $R_n^{XY}(s)$ 关于 X 和 Y 具有对称性。但是,无论是 $W_n^{XY}(s)$ 还是 $R_n^{XY}(s)$,都不具有关于时间序列的传递性或共轭传递性,即对于 3 个时间序列 X, Y 和 Z ,有

$$\left. \begin{matrix} W_n^{XY}(s) \\ W_n^{YZ}(s) \end{matrix} \right\} \not\Rightarrow W_n^{XZ}(s) \text{ 且 } \left. \begin{matrix} R_n^{XY}(s) \\ R_n^{YZ}(s) \end{matrix} \right\} \not\Rightarrow R_n^{XZ}(s) \quad (6)$$

设共有 n 个同步采样的振动信号,若要对它们两两进行交叉小波变换,则共需进行 $A_n^2 = n(n-1)$ 次。考虑到 $W_n^{XY}(s)$ 的共轭对称性和 $R_n^{XY}(s)$ 的对称性,则所需交叉小波变换的次数可减为 $C_n^2 = n(n-1)/2$ 。由于两种时频相干谱 $W_n^{XY}(s)$ 和 $R_n^{XY}(s)$ 都不具有传递性或共轭传递性,要得到所有信号两两之间的时频相干关系,所需交叉小波变换的次数不能

在 $C_n^2 = n(n-1)/2$ 的基础上继续减少, 这样, 在信号数量较多时就会产生较大的运算量。

在实际的工程应用中, 往往没有必要建立完整的时频相干网络, 而应该根据所关心的物理问题和所研究对象的结构及动力学特性, 合理地布置测点, 并确定需要哪些信号之间建立联系。下面是一个简单的示例。

图 2 为一个左端受完全约束的长方体形弹性体, 在其上表面与竖直面交线的交线上, 设有 A, B 两个三向的振动加速度测点。假设此弹性体只发生小变形, 因而可以作为一个线性问题来处理。根据材料力学的相关知识, 可得弹性体单纯的物理形变与信号对之间的对应关系, 如表 1 所示。

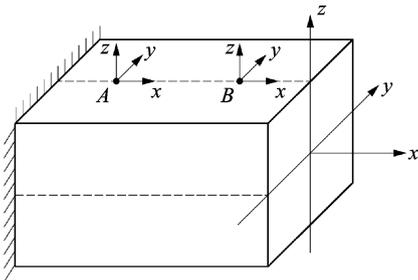


图 2 一端受完全约束的弹性体和它的两个振动测点

Fig. 2 Elastic body fully fixed at one end and its two vibration measuring points

表 1 弹性体的物理变形与信号对的对应关系

Tab. 1 Correspondence between physical deformations of the elastic body and the signal pairs

物理变形	信号对
x 向的拉压变形	$A_x \leftrightarrow B_x$
y 向的剪切变形	$A_y \leftrightarrow B_y$
z 向的剪切变形	$A_z \leftrightarrow B_z$
绕 x 轴的扭转变形	$A_y \leftrightarrow B_y$
绕 y 轴的弯曲变形	$A_x \leftrightarrow B_x$
绕 z 轴的弯曲变形	无

由于两个测点均位于上表面的对称线上, 这里没有与绕 z 轴的弯曲变形所对应的信号对, 可通过增加传感器或改变传感器的位置来解决这个问题。由表 1 可知, 传感器对 $A_x \leftrightarrow B_x$ 同时反映 x 向的拉压变形和绕 y 轴的弯曲变形, 传感器对 $A_y \leftrightarrow B_y$ 同时反映 y 向的剪切变形和绕 x 轴的扭转变形。

如果所关心的是弹性体的复合变形, 则组成它的单纯变形在小变形假设下满足线性叠加原理, 可通过将与它们所对应的所有信号对进行时频相干分析来获取关于复合变形的完整信息。对于这个示

例, 只要搭建图 3 所示的网络, 进行 3 次的交叉小波变换, 就能涵盖表 1 中前 5 种变形的信息。

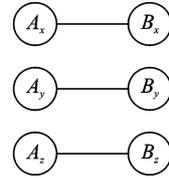


图 3 与图 2 相对应的网络结构

Fig. 3 The network structure corresponding Fig. 2

尽管图 3 并没有网络的形状, 但从本质上讲, 它也是一种类型的网络, 只是这个网络并不完全连通。另外, 本研究中的网络可与图论中的无向图相对应, 信号节点对应于无向图中的节点, 信号节点之间的连线对应于无向图中的边。

1.3 多分形谱的估计

下面对网络中每个信号对的时频相干谱进行多分形分析, 即估计出它们的多分形谱。

1.3.1 多分形谱的定义

令 $\alpha \geq 0$, F 为一个 d 元函数, 若对于足够小的正数 a , 总存在常数 $C > 0$ 和次数小于 α 的多项式 P_{x_0} , 使得式(7)成立, 则 $F \in C^\alpha(x_0)$

$$|F(x_0 + a) - P_{x_0}(x_0 + a)| \leq C|a|^\alpha \quad (7)$$

其中: $x_0 \in \mathbf{R}^d$; $x_0 + a$ 表示 x_0 的每个分量均与 a 相加所得的 \mathbf{R}^d 中的点。

那么 F 在 x_0 处的 Hölder 指数可定义为

$$h_F(x_0) = \sup\{\alpha: F \in C^\alpha(x_0)\} \quad (8)$$

设点集 $X \subset \mathbf{R}^d$ 可被 d 维空间中一系列半径为 r_i 的球体 B_i 所覆盖, 则 X 的 k ($k \geq 0$) 维 Hausdorff 测度 $M_H^k(X)$ 定义为

$$M_H^k(X) = \inf \sum_i r_i^k \quad (9)$$

X 的 Hausdorff 维数 $\dim_H X$ 可定义为

$$\dim_H X = \inf\{k \geq 0: M_H^k(X) = 0\} \quad (10)$$

d 元函数 F 的多分形谱 $D_F(h)$ [16] 可定义为

$$D_F(h) = \dim_H\{x \in \mathbf{R}^d: h_F(x) = h\} \quad (11)$$

简而言之, 函数 F 的多分形谱 $D_F(h)$ 是 F 中 Hölder 指数为 h 的自变量集合的 Hausdorff 维数。

1.3.2 多分形谱的估计

时频相干谱是一个二维的数据集, 它可以被认为是对其二元函数的离散采样。时频相干谱的多分形谱是它所对应的二元函数的多分形谱。由于无法得到此二元函数的具体形式, 在实际应用中只能通

过时频相干谱的数据来对此二元函数的多分形谱进行估计,估计的结果是理论多分形谱上的一些离散点。

目前,能对二维数据的多分形谱进行有效估计的方法并不多,考虑到在计算量、适用范围和计算结果的可靠性等方面的优势,笔者推荐采用基于小波领袖的二维数据多分形谱估计方法。首先,对二维数据进行二维离散小波变换,得到小波系数,进而产生小波领袖;其次,通过小波领袖来构造结构函数;最后,由结构函数来得到二维数据多分形谱上一些离散点的估计。相关的理论背景和具体的计算过程可参考文献[17]。

1.4 多分形特征的提取

在得到多分形谱上离散点的估计以后,还得进行进一步的特征提取,因为要对一个多分形谱进行较为精细的估计,通常需要估计出它上面的十几到几十个,若直接以这些点的横纵坐标作为多分形谱的特征向量,则会因维数过高而变得不便处理。由于常见的多分形谱的形状较为简单,通常是一个无拐点的凹函数,笔者采用形态参数拟合的方法来提取多分形谱的特征,即根据所估计出来的多分形谱上离散点的分布形态,选用形状与之吻合但含有待定参数的简单曲线来拟合这些估计点,用曲线最终的拟合参数作为多分形谱的特征。图 4 为一个典型的应用示例。

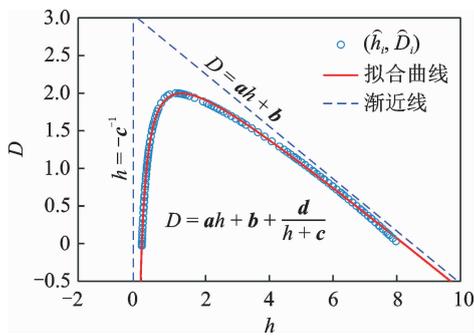


图 4 多分形谱的特征提取

Fig. 4 Feature extraction of the multifractal spectrum

图 4 中的淡蓝色小圆圈为所估计出来的多分形谱上的离散点,其分布形态好似一个倒置的对勾,还可以认为它有两条渐近线,其中一条基本竖直,因此可用函数

$$D(h) = ah + b + \frac{d}{h + c} \quad (12)$$

来对其进行最小二乘拟合。 $D(h)$ 含有 a, b, c, d 这 4 个待定参数,并有两条渐近线

$$h = -\frac{1}{c} \quad (13)$$

$$D = ah + b \quad (14)$$

由图可以看出,曲线很好地拟合了多分形谱的估计点,最后得到相应的特征向量 (a, b, c, d) 。

1.5 特征融合与维数约简

经过前述过程的处理,可得到多个特征向量,分别与网络中的每对相邻节点相对应,整个网络的最终特征可由这些特征向量融合而来。这是一个特征级融合与维数约简的问题,可借助于一定的理论和算法来实现。文献[18]对多种相关的算法进行了系统的分类和介绍,在实际应用中可根据具体问题的特点来选用适当的方法,以得到整个时频相干网络的最终特征。

2 在裂纹故障诊断中的应用

2.1 诊断对象与测试系统

本实例要诊断的是某 12.7mm 高射机枪自动机上的裂纹故障。自动机是自动武器的核心部件,负责完成供输弹、击发、抽壳及抛壳等一系列自动武器连续射击所必需的动作。机枪的自动机可借助于弹药击发时释放的化学能来完成这些动作,而不需要外系统的能量供给,只有在开始射击前需要人为地拉一次枪栓。此机枪的自动机涉及到枪机头、闭锁片、机框、机匣和供输弹机构等主要零部件,其闭锁机构如图 5 所示。

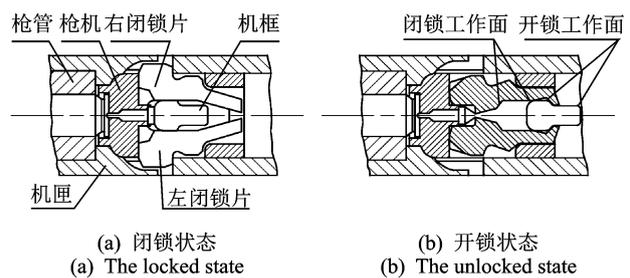


图 5 某 12.7 mm 高射机枪的闭锁机构
Fig. 5 The locking mechanism of a 12.7 mm antiaircraft machine gun

在机枪射击过程中,机框会带动枪机和闭锁片在机匣中做高速的往复运动,其间要完成闭锁、击发、开锁等关键动作,每个动作都伴随着强烈的撞击,这使得枪机和闭锁片等主要受力零件在其应力集中的部位容易产生裂纹。这些裂纹若不能被及时发现,就有可能引发零件的突然断裂,严重影响机枪

的可靠性和操作安全性。本实例在枪机和闭锁片上容易出现裂纹的部位分别设置了3种裂纹故障,它

们均是由线切割机床加工得到的开裂纹,其具体位置和尺寸如图6所示。

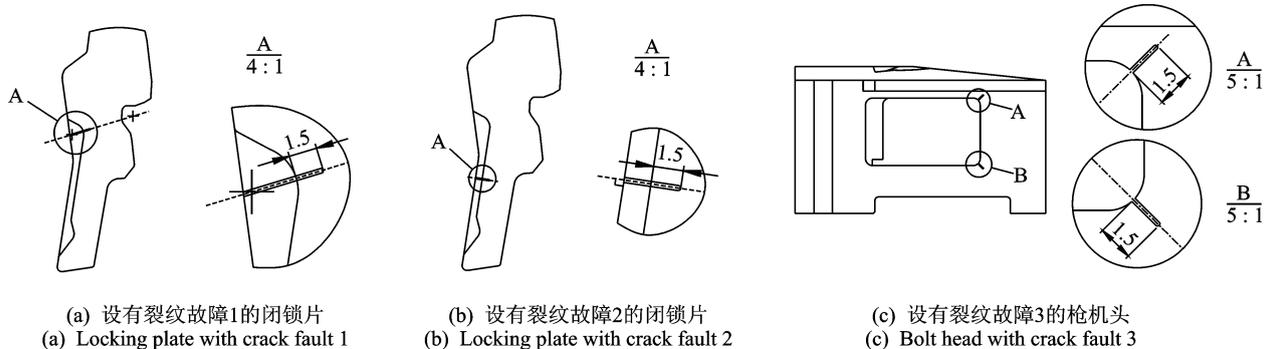


图6 闭锁机构上裂纹故障的设置

Fig. 6 Crack faults set in the locking mechanism

由于枪机和闭锁片均位于枪体内部,尺寸也较小,并且在机枪射击时要做高速的往复运动,因此无法直接在它们上面安装传感器。本实例中的两个振动加速度测点均布置在了枪体的上表面,它们分别靠近机框复进行程末和后坐行程末发生撞击的部位,且都位于机枪关于左右两侧的中称面上。这样,3种裂纹故障再加上无故障的状态共是4种工况,在这4种工况下分别进行多次的实弹发射,并同时采集这两个测点3个正交方向上的振动加速度信号。机枪试验台如图7所示。



图7 机枪试验台

Fig. 7 The machine gun experimental platform

2.2 网络的搭建及其特征提取

由于传感器安装在枪身上,枪身与枪架固连,枪架底部又固定在试验台上,则枪身、枪架和试验台可用图8左侧的结构简图表示。在机枪射击时,枪身要受到弹药气体、子弹以及机枪其余部分的作用,尤其是来自于枪机头和闭锁片的撞击,这些作用使枪架和枪身产生动态的变形和振动。考虑到此机枪的左右对称性,这里只使用两个振动测点 x 向和 z 向

的加速信号,按图8右侧所示的网络结构来组建网络。与图2中的结构类似,这里的 $A_x \leftrightarrow B_x$ 可以反映两个测点间的枪身部分沿 x 向的拉伸变形, $A_z \leftrightarrow B_z$ 反映的则是此部分沿 z 向的剪切变形以及此部分和枪架绕 y 轴的弯曲变形。

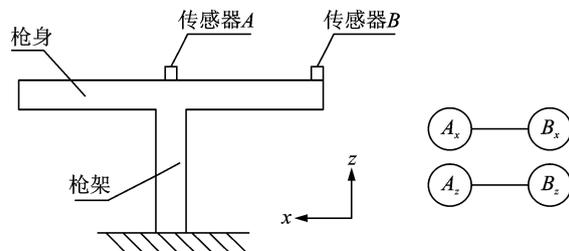


图8 试验系统的结构简图与相应的信号网络

Fig. 8 Structural sketch of the experimental system and the corresponding signal network

在每种工况下都进行多次的射击测试,对采集的振动信号首先进行截断处理,以得到故障信息更加集中且只对应于单次射击循环的信号段。截断开始于机框复进行程末期闭锁撞击刚要发生的时刻,终止于机框后坐行程末期后坐撞击所激发的振动响应已经大幅度衰减的时刻。按照前文所述的方法,对相应于每个单次射击循环的振动信号段进行处理。本实例是对 $A_x \leftrightarrow B_x$ 和 $A_z \leftrightarrow B_z$ 分别进行交叉小波变换,再提取各自相干系数谱的多分形特征。

图9是对应于一个射击循环的两对振动信号的中间处理结果,其中相干系数谱中的红色实线标志了小波变换中边界效应的影响范围。在进行多分形谱的曲线拟合时采用了与式(12)相同的函数模板,这样由每对信号可得到4个特征量。由于本实例的信号网络中只有两个信号对,这里直接将这两个信号对的特征量进行拼接,从而形成一个8维的特征

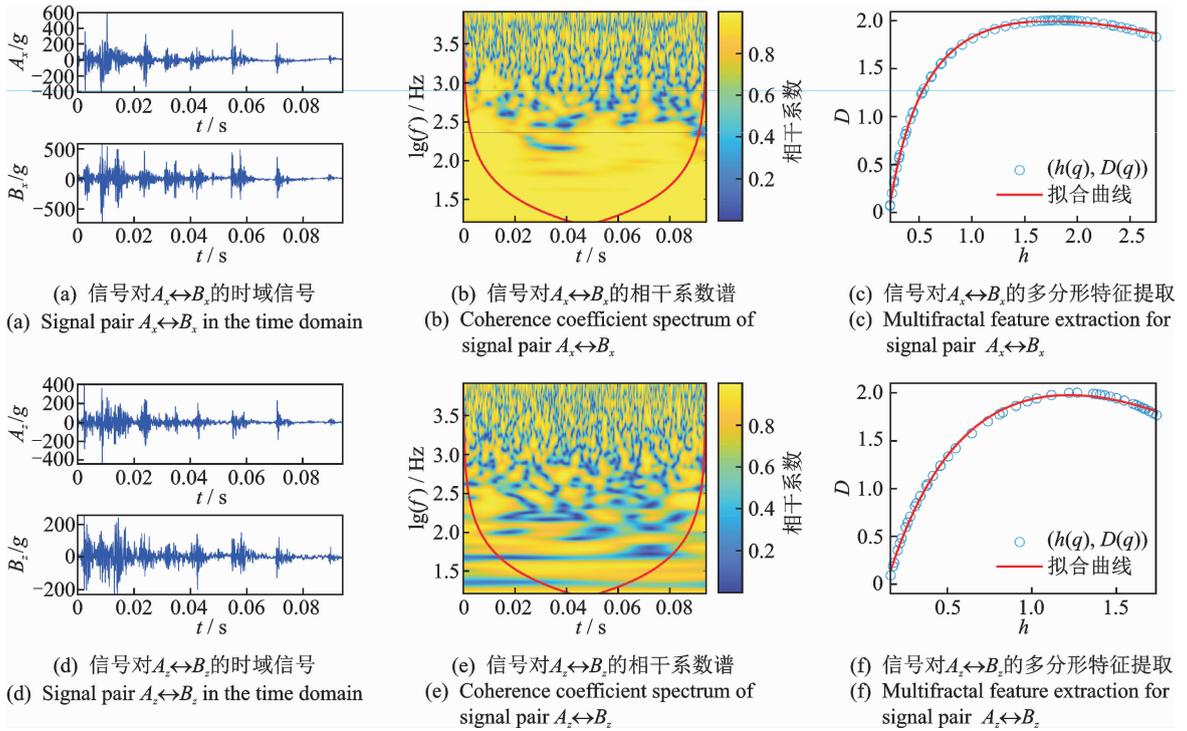


图 9 时频相干网络的特征提取

Fig. 9 Feature extraction of the time-frequency coherence network

向量来作为整个网络最终的特征样本。如果实际应用中的信号对较多,在得到每个信号对的特征以后,还应选用适当的方法来进行融合与降维,以利于分类器的后续处理。

2.3 故障分类

2.3.1 特征样本、分类器与分类结果

取每种工况各 14 个特征样本来进行分类器的训练与性能测试。这里使用了两种类型的分类器:a. 以高斯函数为内核的支持向量机分类器^[19],采用一对一的多分类扩展方案^[20];b. 以决策树为基分类器^[21],采用 RUSBoost^[22]方法集成的分类器。用 4 种工况共 56 个特征样本分别对每种分类器进行折叠数为 5 的交叉训练,首先,将 56 个特征样本大致分为 5 等份,每次用其中的 4 份作为训练样本,用剩下的 1 份作为测试样本,看测试样本被训练好的分类器所预测的故障类别正确与否;其次,依次轮换不同的组份作为测试样本,用其余的组份作为训练样本,再次进行分类器的训练和测试,这样共可进行 5 次;最后,每个特征样本都曾作为测试样本出现 1 次,看所有特征样本在其作为测试样本时被训练好的分类器所预测的故障类型的正确率。交叉训练的方法可以充分利用有限的特征样本,其结果可以反映分类器对于未参与训练的特征样本的预测能力。这两种分类器在交叉训练中对测试样本的预测结果汇总如图 10 所示。

		真实的类型				
		无故障	故障1	故障2	故障3	汇总
预测的类型	无故障	10 17.9%	1 1.8%	2 3.6%	1 1.8%	71.4% 28.6%
	故障1	1 1.8%	12 21.4%	0 0.0%	0 0.0%	92.3% 7.7%
	故障2	1 1.8%	1 1.8%	12 21.4%	3 5.4%	70.6% 29.4%
	故障3	2 3.6%	0 0.0%	0 0.0%	10 17.9%	83.3% 16.7%
汇总		71.4% 28.6%	85.7% 14.3%	85.7% 14.3%	71.4% 28.6%	78.6% 21.4%

(a) 支持向量机的预测结果

(a) Prediction results of the support vector machine classifier

		真实的类型				
		无故障	故障1	故障2	故障3	汇总
预测的类型	无故障	13 23.2%	1 1.8%	1 1.8%	1 1.8%	81.3% 18.8%
	故障1	0 0.0%	11 19.6%	0 0.0%	0 0.0%	100% 0.0%
	故障2	0 0.0%	0 0.0%	13 23.2%	0 0.0%	100% 0.0%
	故障3	1 1.8%	2 3.6%	0 0.0%	13 23.2%	81.3% 18.8%
汇总		92.9% 7.1%	78.6% 21.4%	92.9% 7.1%	92.9% 7.1%	89.3% 10.7%

(b) RUSBoost的预测结果

(b) Prediction results of the RUSBoost classifier

图 10 交叉训练中两种分类器的预测结果

Fig. 10 Prediction results of the two classifiers in the cross training

图 10(a)和(b)也称为类别混淆矩阵。图中绿色边框单元格中上下两个数字分别表示各个类别被分类器正确预测的样本个数和它们占有所有样本的比例;红色边框单元格中上下两个数字则分别表示被分类器错误预测的样本个数和它们占有所有样本的比例,其位置还体现了关于这些样本具体的故障类型信息;无颜色边框单元格中的数字则是对各个类别和所有类别样本分类结果的汇总,其上下两个数字分别代表了预测的正确率和错误率。

2.3.2 对分类结果的讨论

由图 10 可知:支持向量机分类器对所有测试样本总的分类正确率为 78.6%,对无故障和故障 3 类型样本的分类正确率最低,为 71.4%,被误判为故障 2 的样本所占的比重最高,为 29.4%;由 RUSBoost 方法所构建的分类器对所有测试样本总的分类正确率为 89.3%,对故障 1 样本的分类正确率最低,为 78.6%,被误判为故障 1 和故障 2 的样本个数均为 0。这两种分类器的预测结果都比较理想,RUSBoost 方法的预测效果要好于支持向量机。

3 结 论

1) 交叉小波谱和相干系数谱这两种时频相干谱关于时间序列都不具有传递性。在信号数量较多时,要对所有信号两两之间都进行时频相干分析是不可行的,也没有必要。在实际应用中,应根据所关心的物理问题,确定测点的布置方位,并采用合理的网结构。

2) 笔者提出的是一个开放的方法框架,在组网方式、时频相干谱的选型、多分形谱拟合曲线的具体形式以及特征级的融合与降维等问题上,并没有做具体的限定,在实际应用中可根据具体问题的特点来灵活选取。该框架可用于任意数量和各种方位的同步采样振动信号的时频相干多分形特征提取,具有广泛的适用范围。

3) 应用所提出的方法对某 12.7 mm 高射机枪自动机的裂纹故障进行了诊断,诊断中所使用的两种分类器均表现出了较高的诊断正确率,说明了此方法可有效提取裂纹故障的微弱特征,同时验证了将此方法应用于机械设备故障诊断的可行性。

参 考 文 献

- [1] Dasarathy B V. Sensor fusion potential exploitation-innovative architectures and illustrative applications[J]. Proceedings of the IEEE, 1997, 85(1): 24-38.
- [2] Qu Liangsheng, Liu Xiong, Peyronne G, et al. The holospectrum: a new method for rotor surveillance and diagnosis[J]. Mechanical Systems and Signal Processing, 1989, 3(3): 255-267.
- [3] 屈梁生, 邱海, 徐光华. 全息动平衡技术:原理与实践[J]. 中国机械工程, 1998, 9(1): 60-63.
Qu Liangsheng, Qiu Hai, Xu Guanghua. Rotor balancing based on holospectrum analysis: principle and practice[J]. China Mechanical Engineering, 1998, 9(1): 60-63. (in Chinese)
- [4] 韩捷, 关惠玲, 梁川, 等. 矢谱:一种实用的旋转机械故障诊断分析方法[J]. 机械强度, 1998, 20(3): 54-57.
Han Jie, Guan Huiling, Liang Chuan, et al. Vector spectrum: a practical analysis method of the rotary machine fault diagnosis [J]. Journal of Mechanical Strength, 1998, 20(3): 54-57. (in Chinese)
- [5] 段非, 韩捷, 董晶, 等. 全矢谱体系兼容性关键技术研究[J]. 机械设计与制造, 2009(11): 206-208.
Duan Fei, Han Jie, Dong Jing, et al. Research on the key technologies of the full vector system's compatibility[J]. Machinery Design & Manufacture, 2009(11): 206-208. (in Chinese)
- [6] 谷立臣, 张优云. 基于神经元的多传感器数据级融合研究[J]. 机械工程学报, 2003, 39(7): 89-93.
Gu Lichen, Zhang Youyun. Research on multi-sensor data level fusion based on artificial neuron[J]. Chinese Journal of Mechanical Engineering, 2003, 39(7): 89-93. (in Chinese)
- [7] 李毓辉, 卢如平, 方丹, 等. 故障滚动轴承振动信号的半盲处理方法研究[J]. 振动与冲击, 2009, 28(12): 80-83.
Li Yuhui, Lu Ruping, Fang Dan, et al. Research on semi-blind signal processing method for faulty rolling bearing vibration signal[J]. Journal of Vibration and Shock, 2009, 28(12): 80-83. (in Chinese)
- [8] Bin Guangfu, Jiang Zhinong, Li Xuejun, et al. Weighted multi-sensor data level fusion method of vibration signal based on correlation function[J]. Chinese Journal of Mechanical Engineering, 2011, 24(5): 899-904.
- [9] 李火坤, 张宇驰, 邓冰梅, 等. 拱坝多传感器振动信号的数据级融合方法[J]. 振动、测试与诊断, 2015, 35(6): 1075-1082.
Li Huokun, Zhang Yuchi, Deng Bingmei, et al. Study on multi-sensor data-level fusion method of high arch dam vibration signal[J]. Journal of Vibration, Meas-

- urement & Diagnosis, 2015, 35(6): 1075-1082. (in Chinese)
- [10] 王江萍, 娄尚, 杨志芹. 一种机械故障诊断多传感器数据融合特征提取的方法[J]. 西安石油大学学报:自然科学版, 2017, 32(1): 113-118.
Wang Jiangping, Lou Shang, Yang Zhiqin. A feature extraction method of multi-sensor data for mechanical fault diagnosis[J]. Journal of Xi'an Shiyou University: Science and Technology, 2017, 32(1): 113-118. (in Chinese)
- [11] Xiao Fuyuan. A novel evidence theory and fuzzy preference approach-based multi-sensor data fusion technique for fault diagnosis[J]. Sensors, 2017, 17(11): 2504.
- [12] Liu Baoyu, Zhan Xingqun, Zhu Zheng. Multisensor parallel largest ellipsoid distributed data fusion with unknown cross-covariances [J]. Sensors, 2017, 17(7):1526.
- [13] Torrence C, Compo G P. A practical guide to wavelet analysis[J]. Bulletin of the American Meteorological Society, 1998, 79(1): 61-78.
- [14] Grinsted A, Moore J C, Jevrejeva S. Application of the cross wavelet transform and wavelet coherence to geophysical time series[J]. Nonlinear Processes in Geophysics, 2004, 11(5/6): 561-566.
- [15] Maraun D, Kurths J, Holschneider M. Nonstationary Gaussian processes in wavelet domain: synthesis, estimation, and significance testing[J]. Physical Review E, 2007, 75(1/2): 016707.
- [16] Barreira L, Pesin Y, Schmeling J. On a general concept of multifractality: multifractal spectra for dimensions, entropies, and Lyapunov exponents, multifractal rigidity[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 1997, 7(1): 27-38.
- [17] Wendt H, Roux S G, Jaffard S, et al. Wavelet leaders and bootstrap for multifractal analysis of images[J]. Signal Processing, 2009, 89(6): 1100-1114.
- [18] Maaten L V D, Postma E, Herik J V D. Dimensionality reduction: a comparative review[R]. Tilburg: Tilburg University, 2009.
- [19] Scholkopf B, Smola A J. Learning with kernels: support vector machines, regularization, optimization, and beyond[J]. Journal of the American Statistical Association, 2001, 98(462): 489-489.
- [20] Allwein E L, Schapire R E, Singer Y. Reducing multiclass to binary: a unifying approach for margin classifiers[J]. Journal of Machine Learning Research, 2001(1): 113-141.
- [21] Dobra A. Decision tree classification [M] // Liu L, ÖZSU M T. Encyclopedia of Database Systems. New York, NY: Springer New York, 2016: 1-6.
- [22] Seiffert C, Khoshgoftaar T M, Van Hulse J, et al. RUSBoost: a hybrid approach to alleviating class imbalance[J]. Ieee Transactions on Systems Man and Cybernetics Part a-Systems and Humans, 2010, 40(1): 185-197.



第一作者简介: 任海锋,男,1986年6月生,博士生。主要研究方向为机械设备故障诊断。曾发表《基于多分形特征的枪械自动机裂纹故障诊断》(《兵工学报》2018年第39卷第3期)等论文。
E-mail: ren_haifeng@163.com

通信作者简介: 潘宏侠,男,1950年10月生,教授、博士生导师。主要研究方向为测试技术、信号处理和故障诊断。
E-mail: panhx1015@163.com