

基于图建模特征提取的滚动轴承故障诊断

张 迪, 卢国梁

(山东大学机械工程学院 济南, 250061)

摘要 针对滚动轴承运行过程中的早期故障检测与诊断, 提出了一种基于图建模特征提取的滚动轴承故障诊断方法。首先, 结合短时傅里叶变换与图谱理论对信号进行图建模; 其次, 通过随机幂鞅对故障进行检测, 计算邻接矩阵熵值并将其作为特征向量训练支持向量机; 最后, 结合支持向量机对故障进行诊断。分别采用 2 个数据库对本方法进行故障检测与诊断验证, 实验结果表明, 该方法能够有效检测和诊断轴承故障, 并通过与常用方法进行对比, 表明了该方法的优越性。

关键词 滚动轴承; 故障特征提取; 图结构; 故障诊断
中图分类号 TH133.33

引 言

滚动轴承作为机械的基础零部件, 其工作状态对整台设备乃至整个生产线的安全有重大影响。因此, 对其进行故障诊断具有重要意义。但轴承振动信号具有非线性和非平稳性的特点, 仅从时域和频域很难发现故障特征。时频方法有效地弥补了这一不足, 其中主要有短时傅里叶变换(short-time Fourier transform, 简称 STFT)、小波及小波包分析、经验模式分解(empirical mode decomposition, 简称 EMD)等, 并都取得了很好的效果。李恒等^[1]提出了一种基于 STFT 与卷积神经网络的故障诊断方法, 在故障识别精度上有了很大提高。张志刚等^[2]对滚动轴承信号进行 EMD 分解, 得到一系列本征模态函数(intrinsic mode function, 简称 IMF)分量, 运用谱峭度法和包络解调方法对真实 IMF 分量进行分析, 提取故障特征频率。在故障模式识别上, 支持向量机^[3]由于有更好的泛化能力, 被广泛应用到故障诊断中。徐晶等^[4]将小波包分解与支持向量机相结合, 提出了基于小波包能量谱及支持向量机(support vector machine, 简称 SVM)的故障检测方法。石瑞敏等^[5]提出了一种基于局部均值分解(local mean decomposition, 简称 LMD)能量特征的特征向量提取方法并将其与 SVM 相结合来诊断滚动轴承故障。近年来, 基于图结构的方法也应用到故障诊断方面。文献^[6]将图模型应用到旋转机械的异常检测上并取得了很好的效果。

针对滚动轴承信号的特点, 将短时傅里叶变换与图结构相结合, 提出了一种基于图建模特征提取的故障诊断方法, 通过短时傅里叶变换得到信号的时频图, 在每一个窗口内, 选取信号频率区间划分为一定数量的频率段, 以各频率段能量构建图模型, 进而通过对图模型的相似性比较来检测滚动轴承故障, 最后通过 SVM 对故障进行分类。

1 图模型建模

图是通过点和线来描述事物之间的相应关系, 顶点代表事物, 连接顶点的边表示事物之间对应的某种关系^[7]。图谱理论的基本思想是在图和矩阵之间建立对应的关系, 通过矩阵的相关属性来研究图的问题。

短时傅里叶变换的思想是选取一个窗函数 $r(t)$, 将其与信号函数 $x(t)$ 相乘, 然后对其进行傅里叶变换, 不断移动窗函数, 得到信号一系列随时间变化的频谱图。短时傅里叶变换的公式为

$$\text{STFT}_x(\tau, \omega) = \int_{-\infty}^{\infty} [x(t)r(t-\tau)]e^{-j\omega t}dt(1)$$

其中: $x(t)$ 为信号函数; $r(t)$ 为窗函数; τ 为窗口的宽度; ω 为频率; $e^{-j\omega t}$ 为复变函数。

将每一时刻频谱图中的信号频率范围划分为一定数量的频率段, 如图 1(a)所示, 计算各个频率段的能量如图 1(b)所示, 其公式为

$$F_h = \sum_{k=1}^n A_k^2 \quad (2)$$

其中： $k=1, 2, \dots, n$, n 为每个频率段中所包含的频率个数； $h=1, 2, \dots, m$, 为频率段的个数； A_k 为频率段内第 k 个频率的幅值； F_h 为第 h 个频率段的能量。

以各频率段为顶点，以各频率段的能量差值为权重建立图模型，如图 1(c) 所示为 t 时刻的图模型，其中 V 表示顶点， d_{ij} 表示 i, j 两点之间的权重。权重计算如式(3)所示，这样各时刻的频谱图就转化为一个 $N \times N$ 的邻接矩阵，如图 1(d) 所示。

$$d_{ij} = F_i - F_j \quad (3)$$

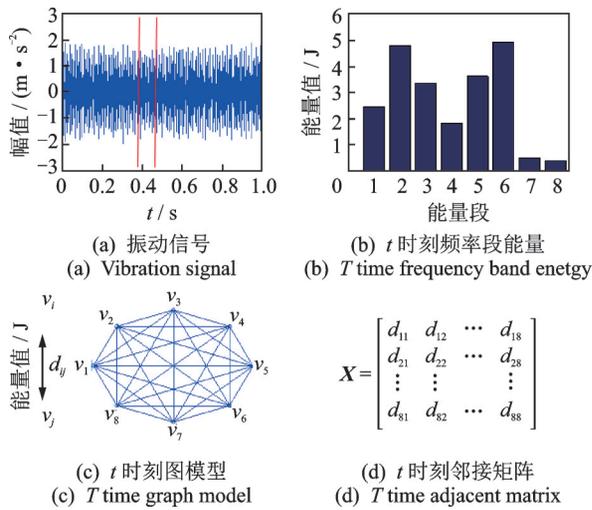


图 1 图模型的建模方法

Fig.1 Modeling method of graph model

2 基于图模型的滚动轴承故障诊断

2.1 方法介绍

当滚动轴承发生故障时，其振动信号也随之发生改变，在频谱中的表现是各频率段的能量发生改变。滚动轴承发生不同的故障，各频率段的能量变化是有很大大差距的，因此由频率段能量建立的图模型也将发生变化。本研究的思想是以各频率段能量构建图模型，通过对图模型的相似性比较来检测轴承故障，最后通过 SVM 对故障进行分类。

图 2 为基于图建模特征提取的滚动轴承故障诊断方法流程图，其步骤如下。

1) 通过 STFT 变换得到信号的时频图，对每一个时刻的频谱图构建图模型。通过对比分析，文中短时傅里叶变换的窗口长度选择 $0.1 \times f_s$, f_s 为采样频率。

2) 通过对图模型产生的邻接矩阵进行比较来进行异常检测。文中采用文献[6]中的方法，对邻接

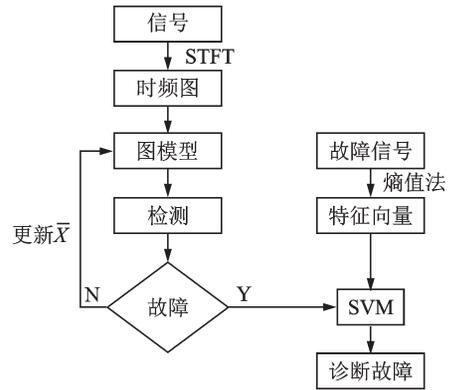


图 2 基于图建模特征提取的滚动轴承故障诊断方法流程图
Fig.2 Flow chart of rolling bearing fault diagnosis method based on feature extraction of graph modeling

矩阵 X_t 进行对角化分解，如式(4)所示

$$X_t = \Gamma Y_t \Gamma^{-1} = \Gamma (Y_t^1) \Gamma^{-1} + \Gamma (Y_t^2) \Gamma^{-1} \quad (4)$$

其中： Y_t 为与 X_t 相似的邻接矩阵； Γ 的每一行对应各特征值的特征向量； Y_t^1 为对角部分，反映的是矩阵内部的波动； Y_t^2 为非对角部分，反映的是矩阵之间的波动。

非对角部分的波动值 z_t 为

$$z_t = \| Y_t^2 \|_F \quad (5)$$

其中： $\|\cdot\|_F$ 表示 F -范数。

对所得到的 $\{z_t\}$ 通过式(6)计算 t 时刻的异常度 s_t

$$s_t = s(\{z_1, z_2, \dots, z_{t-1}\}, z_t) = |z_t - H_t|_1 \quad (6)$$

其中： $H_t = \frac{1}{t} \sum_{i=1}^t z_i$; $\|\cdot\|_1$ 为 L_1 -范数。

然后通过 martingale-test 对邻接矩阵的异常度进行决策，其步骤如下。

1) 通过 s_t 计算随机功率鞅 $M(t)$ ，如式(7)所示

$$M(t) = \prod_{i=1}^t (\psi \hat{p}_i^{s_i-1}) \quad (7)$$

其中： $\psi \in (0, 1)$; \hat{p}_i 的计算公式为

$$\hat{p}_i(\{s_1, \dots, s_{i-1}\}, s_i) = \frac{\#\{j: s(j) > s(i)\} + \theta_i \#\{j: s(j) = s(i)\}}{i} \quad (8)$$

其中： $\#\{\cdot\}$ 为计数函数； θ_i 为 $0 \sim 1$ 均匀分布的随机值； $j \in \{1, 2, \dots, i-1\}$ 。

2) 设定阈值 λ ，当 $M(t) > \lambda$ 时，表示滚动轴承故障，系统停止检测。 λ 的取值通过人为经验设定，它的大小决定着误检测率的上界，可根据用户接受的误检率决定^[8]。

3) 检测出故障后，通过 SVM 对故障进行分类。由于故障位置不同，各个能量段的能量变化也就不

同,因此邻接矩阵每一行的权重也就不一样。文中采用熵值法计算邻接矩阵的每一行的权重,将其作为特征向量输入SVM进行训练。熵值法确定权重步骤如下。

1) 计算第 j 列下第 i 项占该指标的比重

$$p_{ij} = d_{ij} / \sum_{i=1}^n d_{ij} \quad (i=1,2,\dots,n; j=1,2,\dots,m) \quad (9)$$

2) 计算第 j 列的熵值

$$e_j = -k \sum_{i=1}^n p_{ij} \ln(p_{ij}) \quad (10)$$

3) 计算信息熵冗余度

$$h_j = 1 - e_j \quad (11)$$

4) 计算各项指标的权重

$$w_j = h_j / \sum_{j=1}^m h_j \quad (12)$$

5) 计算各行的权重

$$Q_i = \sum_{j=1}^m w_j p_{ij} \quad (13)$$

2.2 滚动轴承频率区间的选取

在相同负载条件下,同型号的轴承,其故障特征频率基本一致,因此文中通过对同型号轴承的各故障信号与正常信号进行对比分析,找出由于故障导致的主要频率变化区间,将其作为人们进行故障检测与诊断的频率区间。

3 实验

文中的方法是先进行故障检测再进行故障诊断,在故障检测时需要轴承从正常到失效的完整数据,而故障诊断时需要大量的故障数据来进行SVM分类。由于没有大量的滚动轴承失效完整数据,因此在故障检测和诊断时分别采用两套数据。故障检测采用法国弗朗什孔泰大学的数据,其中包含了滚动轴承从正常到失效的完整数据;故障诊断采用西储大学的数据库,其中包含滚动轴承各种故障状态的大量数据。

3.1 故障检测

实验数据选择来自法国弗朗什孔泰大学 FEMTO 研究所的 PRONOSTIA 试验台^[9]。PRONOSTIA 试验台通过加速寿命试验使滚动轴承在短时间内迅速失效,采集轴承各种条件下的失效数据。其数据的工况信息如表1所示。

图3为工况1下轴承1-3的振动信号时域图,采

表1 PRONOSTIA 试验台工况信息

Tab.1 Working condition information of PRONOSTIA

工况	轴承个数	转速/($\text{r}\cdot\text{min}^{-1}$)	载荷/N
1	7	1 800	4 000
2	7	1 650	4 200
3	7	1 500	5 000

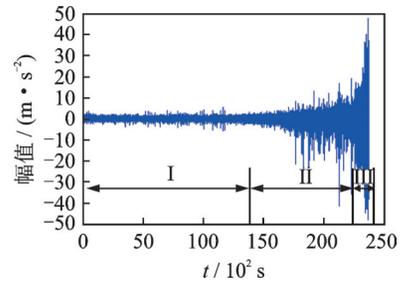


图3 轴承1-3振动信号时域图

Fig.3 Bearing 1-3 vibration signal time domain diagram

用相对均方根(relative root mean square, 简称RRMS)作为退化评估指标^[10],对轴承不同运行状态进行准确划分。如图3所示,轴承整个失效过程可以分为3个阶段:第I阶段为平稳期,信号幅值相对稳定在一个较低的水平;第II阶段为退化期,幅值开始变大但增长幅度较慢;第III阶段为失效期信号幅值迅速增大,所要做的就是轴承失效前检测出轴承故障。通过对比平稳期、退化期和失效期的频谱图,得出轴承从平稳期到失效期,其频率主要在0~4 000 Hz发生变化,因此选取0~4 000 Hz作为频率区间进行故障检测。

频率区间确定后,频率段长度的选择也非常重要,如果选取的频率段太窄,对噪声敏感,不能有效检测出故障,选取的频率段太宽,又不能准确定位故障区域。文中通过对不同频率段长度进行实验对比,选取200 Hz为频率段长度。

将频率区间划分为每段200 Hz的频率段,计算各频率段的能量,通过各频率段能量差建立图模型,进行故障检测。设定 $\lambda=8$,检测结果如图4所示,图4(a)为轴承振动信号,图4(b)为其功率谱 $M(t)$,随着轴承故障的发展, $M(t)$ 值逐渐增大,当 $M(t)$ 达到所设定的阈值时系统报警,也就是图中红色圆圈所示的位置。当发出警报后,系统将停止检测,可以看出本方法能够在轴承刚进入到退化期就检测出其异常。

分别对各工况下其他轴承进行故障检测,图5,6分别为工况2和工况3下轴承2-3,3-3的故障检测图。从图中可以看出,本方法能够有效检测出故障。如表2所示,本方法能够检测出各工况下所有轴承的故障,检测率达到了100%。

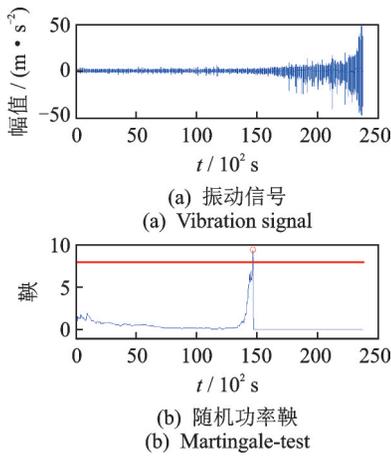


图 4 轴承 1-3 故障检测

Fig.4 Bearing 1-3 fault detection

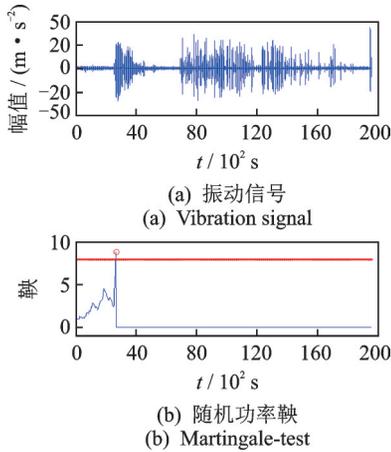


图 5 轴承 2-3 故障检测

Fig.5 Bearing 2-3 fault detection

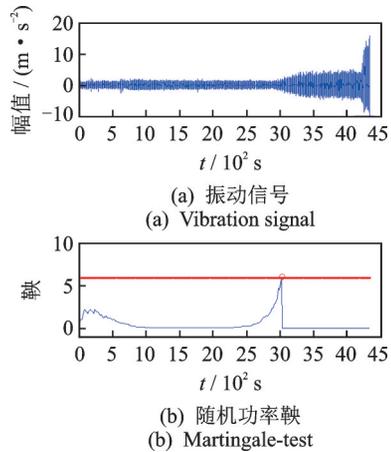


图 6 轴承 3-3 故障检测

Fig.6 Bearing 3-3 fault detection

表 2 PRONOSTIA 试验台轴承故障检测

Tab.2 Bearing fault detection of PRONOSTIA test-bed

工况	轴承个数	故障检测率/%
1	7	100
2	7	100
3	3	100

3.2 故障诊断

实验数据选择美国 Case Western Reserve University 轴承实验中心的滚动轴承故障测试数据,测试轴承为 SKF-6205,信号采样频率为 12 kHz。在轴承的外圈、内圈和滚动体上分别设置损伤直径为 0.177 8, 0.355 6 和 0.533 4 mm 的单点故障,通过加速度传感器获取滚动轴承在正常、内圈故障、外圈故障及滚动体故障 4 种运行状态时的原始振动信号。

通过对正常情况与各种故障类型的频谱图进行对比,发现轴承发生不同故障后,其频谱图主要在 2 kHz~4 kHz 区间内发生很大变化,因此文中选取 2 kHz~4 kHz 作为频率区间,将其划分为每段 200 Hz 的频率段,计算各频率段的能量,通过各频率段能量差建立图模型,通过熵值法计算邻接矩阵每一行的权重作为特征向量输入 SVM 进行训练,进行故障诊断。

如表 3 所示,选取损伤直径为 0.177 8 mm 的内圈故障、外圈故障、滚动体故障,各 60 组数据,共 180 组数据,选取其中的 60 组数据,以图模型邻接矩阵每一行的权重为特征向量输入 SVM 进行训练,剩下的 120 组数据进行测试。文中 SVM 的核函数选用径向基核函数,利用交叉验证和网格搜索的方法来寻找最佳参数 C 和核函数参数 δ ,其检测结果如图 7 所示,实际类别“○”与诊断类别“*”完全符合,准确率达到了 100%。

表 3 SVM 分类的输入参数

Tab.3 Input parameters of classification by SVM

参 数	内圈故障	滚动体故障	外圈故障
训练样本个数	20	20	20
测试样本个数	40	40	40
样本标签	1	2	3

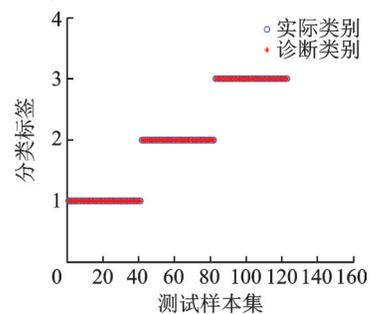


图 7 故障识别结果图

Fig.7 Result of fault identification

3.3 对比实验

将文中方法与基于小波包能量谱、基于 EMD

奇异熵等方法进行比较,结果如表4所示,可以看出文中方法诊断效果明显优于其他方法。

表4 不同方法的诊断结果

Tab.4 Diagnostic results of different methods

算 法	检测率/%
小波包能量谱 ^[4]	98.25
EMD 奇异熵 ^[11]	83.3
LMD+SVM ^[12]	97.5
文中方法	100

4 结 论

1) 针对滚动轴承故障诊断问题,提出了一种基于图建模特征提取的滚动轴承故障诊断方法,提取了一种新的特征来建立图模型。通过短时傅里叶变换得到信号的时频谱,提取每一个窗口的频谱图,计算其频率区间内各频率段的能量,以各频率段为顶点,以能量差值为权重构建图模型,通过对邻接矩阵的相似性比较来检测轴承故障。

2) 针对建立的图模型,提取了一种新的特征用来进行SVM训练,进而诊断故障。图模型邻接矩阵的每一行代表着一个频率段能量与其他能量段能量的相对变化量,采用熵值法计算图模型邻接矩阵每一行的权重,并将其作为特征来训练SVM,进而确定故障类型。

3) 通过实验,证明了文中方法能够有效检测出滚动轴承故障并准确判断出故障类型。

参 考 文 献

- [1] 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.
LI Heng, ZHANG Qing, QIN Xianrong, et al. Fault diagnosis method for rolling bearings based on short-time Fourier transform and convolution neural network [J]. Journal of Vibration and Shock, 2018, 37 (19): 124-131. (in Chinese)
- [2] 张志刚,石晓辉,施全,等.基于改进EMD和谱峭度法滚动轴承故障特征提取[J].振动、测试与诊断,2013,33(3):478-482.
ZHANG Zhigang, SHI Xiaohui, SHI Quan, et al. Fault feature extraction of rolling element bearing based on improved EMD and spectral kurtosis [J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33 (3): 478-482. (in Chinese)
- [3] VAPNIC V. The nature of statistical learning theory [M]. Berlin: Springer Science & Business Media, 2013: 202-262.
- [4] 徐晶,刘德坤,刘彦慧.基于小波包能量谱及SVM算

法的轴承故障检测[J].黑龙江科技大学学报,2015,25(1):110-114.

XU Jing, LIU Dekun, LIU Yanhui. Bearing fault detection method based on wavelet packet energy spectrum and SVM algorithm [J]. Journal of Heilongjiang University of Science & Technology, 2015, 25 (1): 110-114. (in Chinese)

- [5] 石瑞敏,杨兆建.基于LMD能量特征的滚动轴承故障诊断方法[J].振动、测试与诊断,2015,35(5):832-836.
SHI Ruimin, YANG Zhaojian. Fault diagnosis method of rolling bearing based on LMD energy characteristics [J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35 (5): 832-836. (in Chinese)
- [6] LU G L, LIU J, YAN P. Graph-based structural change detection for rotating machinery monitoring [J]. Mechanical Systems and Signal Processing, 2018, 99: 73-82
- [7] 张清华.图论及其应用[M].北京:清华大学出版社,2013:34-54.
- [8] HO S S, WECHSLER H. A martingale framework for changes in data streams by testing exchangeability [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(12): 2113-2127.
- [9] PATRICK N, RAFAEL G, KAMAL M, et al. PRO-NOSTIA: an experimental platform for bearings accelerated life test [C] // In Proceedings of IEEE International Conference on Prognostics and Health Management. Denver, CO, USA: IEEE, 2012: 1-8.
- [10] 燕晨耀.基于多特征量的滚动轴承退化状态评估和剩余寿命预测方法研究[D].成都:电子科技大学,2016.
- [11] 许鹭,田晶,王志.基于EMD熵特征融合的中介轴承故障特征提取方法[J].沈阳航空航天大学学报,2017,34(6):16-21.
XU Lu, TIAN Jing, WANG Zhi. Fault feature extraction method of intershaft bearing based on feature fusion of EMD entropy [J]. Journal of Shenyang Aerospace University, 2017, 34 (6): 16-21. (in Chinese)
- [12] 谢平,杨玉昕,江国乾.基于局部均值分解的滚动轴承故障诊断新方法[J].计量学报,2014,35(1):73-77.
XIE Ping, YANG Yuxin, JIANG Guoqian. A new fault diagnosis method based on local mean decomposition for roller bearings [J]. Acta Metrologica Sinica, 2014, 35 (1): 73-77. (in Chinese)



第一作者简介:张迪,男,1985年8月生,硕士生。主要研究方向为滚动轴承在线故障监测与诊断。曾发表《基于图结构的轴承故障诊断》(《轴承》2019年第9期)等论文。

E-mail: 439394430@qq.com