

DOI:10.19651/j.cnki.emt.2108686

一种强噪声背景下地铁车轮轴承故障信号的特征提取方法

贾鑫 梅劲松

(南京航空航天大学自动化学院 南京 211106)

摘要: 针对地铁车轮轴承的声学故障诊断中背景噪音大、难以提取出有效故障特征的问题,提出了一种在强噪声背景下故障特征提取的方法。对声音信号进行短时傅里叶变换(short-time Fourier transform, STFT)得到时频图,时频图中的条纹就是故障特征;沿条纹方向将图像各个点的信号强度相加,得到时频图对应的信号强度叠加折线图来展示故障特征,并且提出一种基于峰值高度的自适应循环降噪算法对信号强度叠加折线图进行降噪,得到该折线图的评价指标为有效峰值数目;最后提出一种自适应滑动窗口检测法来截取时频图中条纹分布的区域,以此来得到最优的故障特征展现效果。实验结果表明,所提出的方法可以从采集的音频信号中提取出来明显有效的故障特征。

关键词: 轴承故障诊断;特征提取;时频图;降噪算法

中图分类号: TH133.33 **文献标识码:** A **国家标准学科分类代码:** 510.4040

Feature extraction method of subway bearing fault signal under strong noise background

Jia Xin Mei Jinsong

(College of Automation, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China)

Abstract: Aiming at the problem of large background noise and difficulty in extracting effective fault features in the acoustic fault diagnosis of subway wheel bearings, a method for fault feature extraction under strong noise background was proposed. Perform short-time Fourier transform (STFT) on the sound signal to obtain a time-frequency diagram, and the stripes in the time-frequency diagram are the fault features; add the signal intensities of each point of the image along the direction of the stripes to obtain the time-frequency diagram. The signal intensity corresponding to the graph is superimposed on a line graph to show the fault characteristics; and an adaptive cyclic noise reduction algorithm based on the peak height is proposed to reduce the noise of the signal intensity superposition line graph, and the evaluation index of the graph is the number of effective peaks; finally An adaptive sliding window detection method is proposed to intercept the fringe distribution area in the time-frequency graph, so as to obtain the optimal fault feature display effect. Experimental results show that the proposed method can extract obvious fault features from the collected audio signals.

Keywords: bearing fault diagnosis; feature extraction; time-frequency diagram; noise reduction algorithm

0 引言

在地铁运行的过程中,列车轮对轴承故障是导致列车发生故障甚至造成严重后果的最主要的原因。使用声学方法来检测轴承故障,检测设备可以无接触安装、可以检测出早期微弱故障,使用前景非常广阔。但地铁运行的过程中会产生大量的随机噪音,故障信号微弱难以被识别。

针对强噪声背景下提取轴承微弱故障特征的问题,近

些年来有很多研究^[1-2]。经验模态分解(empirical mode decomposition, EMD)及其各类衍生方法,可以从原始信号中提取出来故障特征^[3-5]。但是这类方法存在一系列的问题,经验模态分解会出现模态混叠和端点效应的问题;其改进方案集成经验模态分解^[6](ensemble empirical mode decomposition, EEMD)不能完全消除模态混叠问题,反而增加了很多计算量;变分模态分解^[7](variational mode decomposition, VMD)通过不断寻找每个分量的中心频率

与带宽可以抑制模态混叠和端点效应的问题,但是模态分量个数需要通过实验人为确定,有一定的局限性。人工神经网络 (artificial neural networks, ANNs) 可对时域信号^[8-9]、或信号的时频图^[10]进行特征提取,是近年来非常热门的方法。使用神经网络直接对原始信号提取故障特征^[11-13],这种方法需要多层网络通过大量学习才可以提取到有效的特征,不仅对网络结构要求严格,还需要大量的数据集以及较长的模型训练时间;使用神经网络对原始信号的时频图进行特征提取^[14-15],相对来说特征提取更加容易,因为时频图已经对原始信号进行了一次特征提取,但是时频图数据量仍然较大,需要复杂的网络和较多的参数,影响学习效率以及模型的应用性能。

本文从原始信号的时频分析出发,对时频图信号进行纵向叠加得到新的信号表现形式,即信号强度叠加折线图。提出基于峰值高度的自适应循环降噪算法,得到信号强度叠加折线图的评价指标,在此基础上提出一种自适应滑动窗口检测算法来确定故障特征分布的区间,得到最优信号强度叠加折线图来展现故障特征,这种表现形式更加轻量化且故障特征更加明显。

1 STFT 变换及信号强度叠加折线图

1.1 原始信号简介

使用声音采集阵列来采集地铁车轮轴承的声音信号,阵列有效长度为 7.62 m,采集板型号为 iDSC 1816,采样频率为 76 800 Hz。iDSC 1816 将 8 个 16 位的同步数据采集通道和每个通道上的砖墙式抗混叠滤波器结合起来,提供高质量的信号。

如图 1 所示为信号时域对比图,其中图 1(a)所示为一个正常信号时域波形图,图 1(b)和图 1(c)为两个故障信号




图 1 信号时域对比图

的时波形域图,可以看到时域信号含有大量噪音且无法识别出来有效的故障特征。

1.2 原始信号的 STFT 变换

时域分析和频域分析处理周期性平稳信号具有较好的效果,但在处理非周期性非平稳信号时有很大的局限性。短时傅里叶变换(STFT)是 D. Gabor 于 1946 年提出,引入时间局部化的窗函数,同时含有时域与频域信息,能够更全面反映旋转机械的故障状态信息。由于随机噪音的存在,地铁车轮轴承的故障信号是非平稳信号,因此选取 STFT 进行时频分析。

短时傅里叶变换基本思想是把时域和频域分解为大小相等的小窗口,然后移动窗函数,进行各个不同时刻的频率与相位的分析。实验中所用到的信号是离散信号,离散短时傅里叶变换公式为:

$$F_{STFT}(m, n) = \sum_{k=0}^{N-1} x(k)g^*(k-m)c^{-j2\pi nk/N} \quad (1)$$

其中, $x(k)$ 为输入信号序列, $g(m)$ 为窗函数, N 为窗宽度。进行 STFT 变换时,不同的窗函数、窗口长度、重叠样本数、变换点数等参数,会对变换的效果产生影响。经过多次实验,选取窗函数为 Blackman 窗、窗口长度 256、重叠样本数为 192、变换点数为 512 进行 STFT 变换,可以得到比较清晰的故障特征。

时频图中,横坐标为时间,纵坐标为频率,颜色的亮度是信号强度,单位为 dB/Hz。设 s 为 STFT 变换后所得复数矩阵,为了进一步信号处理更方便进行,取 s 的横坐标为时频图的横坐标,取 s 的纵坐标为时频图的纵坐标,取 $20 \times \log_{10}(|abs(s)|)$ 来表示信号强度,这样每一组坐标对应于时频图中的一个像素点。根据以上规则,得到如图 2 所示的正常信号和故障信号的时频图对比图,其中图 2(a)为正常信号时频图,图 2(b)为故障信号时频图。

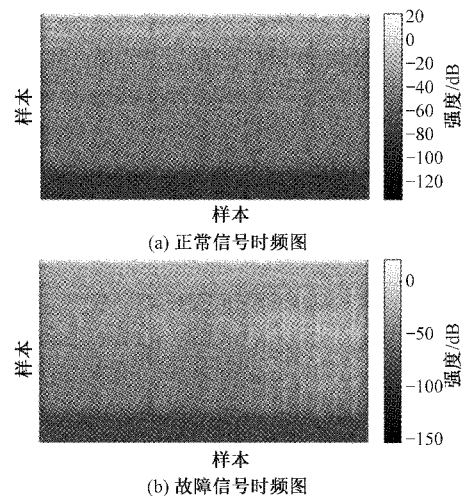


图 2 正常信号与故障信号的时频图对比

由时频图可以看到,跟正常信号相比,故障信号的时频图有竖着的条纹,条纹的颜色较亮说明条纹处的信号强度大,这是由故障引起的振动。

1.3 信号强度叠加折线图的生成

在时频图中,不仅存在着大量噪声,而且条纹的分布区域不均匀、部分条纹非常微弱甚至看不到。为了减少噪声的影响、增强条纹处的故障特征并且压缩信号便于处理,将图像进行纵向压缩,也就是将每个位置的信号强度沿垂直方向相加,横坐标与时频图的横坐标对应。可以看到条纹主要分布在纵坐标的[40,220]区间内,因此只选取这部分的信号进行计算。压缩后进行归一化处理,绘制为折线图,如图3所示为正常信号与故障信号的信号强度叠加折线图对比,其中横坐标为采样点数,纵坐标为信号强度也就是高度。图3(a)为正常信号的信号强度叠加折线图,除噪声外无明显特征;而图3(b)为故障信号的信号强度叠加折线图,有明显的尖峰特征,并且与图2(b)相比,该形式的故障特征更加明显。




图3 正常信号与故障信号的信号强度叠加折线图对比

信号强度叠加折线图中高度较大的尖峰,就对应于时频图中的条纹,高度很小的尖峰就是噪音。到此为止可以用信号强度叠加折线图来表示故障特征,接下来分析如何评价该折线图的品质。

2 信号强度叠加折线图降噪处理及评价指标

2.1 信号强度叠加折线图的降噪处理

由信号强度叠加折线图可以发现,故障特征信号和噪音信号频率相差不大,并且折线图所表示的信号是不平稳的,如果采用普通的滤波器来降噪,会损坏特征信号。因此

提出一种基于相对高度的降噪算法:进行尖峰检测,统计信号强度叠加折线图中所有的尖峰并且计算其相对高度,将尖峰高度小的信号消除。

信号强度叠加折线图中纵坐标是信号强度,横坐标为采样点,尖峰检测算法的流程图如图4所示,其中index为位置索引也就是横坐标的值,图中展示了一个尖峰的检测过程。找到尖峰后,根据相对高度判断它是否需要被消除。尖峰的相对高度为:

$$high[i] = h[i] - \max(Lh[i], Rh[i]) \quad (2)$$

其中, $h[i]$ 为第 i 个尖峰的高度, $Lh[i]$ 和 $Rh[i]$ 分别为左右侧低谷的高度。

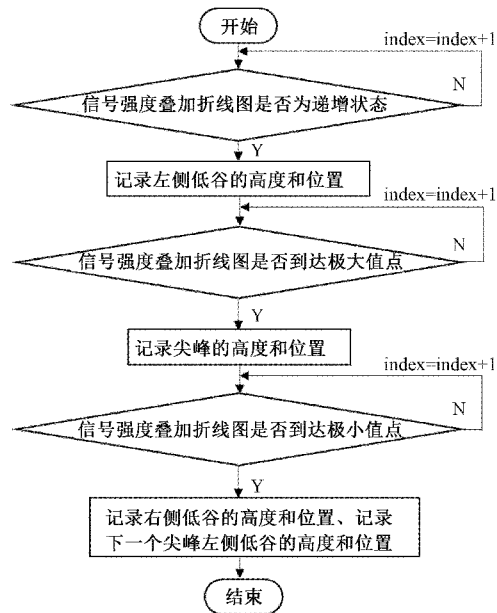


图4 尖峰检测流程图

消除尖峰的做法是,将尖峰的相对高度削平为0,如图5所示,将ABD这一段变为水平的AD段,就消除了ABD这个尖峰。




图5 噪音消除示意图

消除尖峰需要设置一个阈值高度,相对高度小于阈值的尖峰被消除,大于阈值的保留。以图5中的故障信号为

例,假设阈值高度设为 600,就是将相对高度小于 600 的尖峰消除,去除噪声后的折线图如图 6 所示,可以看到噪音去除了很多,故障特征基本得到保留。




图 6 降噪后的折线图

2.2 循环降噪算法

由图 6 可以看到,高度阈值设置为 600,虽然有一定的效果,但是一些应该保留的大尖峰被削弱,却仍然有小的噪声被保留。这是因为计算尖峰相对高度的算法,参考的是尖峰两侧相邻低谷的高度,有一定的不合理性;而且高度阈值一开始就设置,其值的大小不容易确定。

为了改善这个问题,可以进一步改进消除尖峰的算法,提出一种循环降噪的算法,来渐进的消除噪音。首先设置一个初始高度阈值和一个递增量,然后高度阈值每递增一次使用新的阈值对整个折线图进行一次降噪操作,直到可以达到设置的标准,完成降噪过程。

该实验中设置初始高度阈值为 50,递增量为 50,也就是先将折线图中相对高度小于 50 的尖峰消除,再消除相对高度在 $[50,100]$ 区间的尖峰,再消除相对高度在 $[100,150]$ 区间的尖峰,以此类推直到得到效果较好的降噪效果,这种算法可以保证有效尖峰的相对高度计算不被噪音影响。至于这个降噪过程什么时候停止,实验设置的标准是:若尖峰数量小于 20 则认为达到了期待的效果,降噪完成。

如图 7 所示为使用循环降噪算法后,故障信号的最终效果图。与图 6 相比,可以看到有效尖峰更大程度得到了保留,噪音基本上被全部消除,效果提升显著。

2.3 基于峰值高度的自适应循环降噪算法

上面的降噪处理,虽然最后可以获得较好的特征效果图,但是这个降噪过程具体进行多少次,是由人工设定的。根据此次实验所使用的数据样本,设置值为 20,就是当某次降噪处理结束后,若尖峰数量小于 20 则结束降噪处理。这种做法针对当前样本时可以得到不错的效果,但是不具备通用性。若更换数据,该数据所生成的时频图中故障特征条纹缺失较多,如果仍然设置尖峰数量小于 20 为降噪终止的标准,最终的信号强度叠加折线图中会保留一定的噪音无法被进一步消除。

针对以上问题,提出一种基于峰值高度的自适应循环




图 7 使用循环降噪算法的效果图

降噪算法,自适应降噪就是不再人工针对尖峰数量设置降噪终止的标准,而是根据故障特征的分布特点来设置。通过计算可以发现,故障特征峰值的位置分布大体上是等间距的,因此降噪处理的规则为:每次降噪后,统计 n 个尖峰的位置,然后计算 $n-1$ 个距离为 $d_1, d_2 \dots d_{n-1}$,取距离中出现次数最多的数值设置其为标准距离 d ,然后根据 d 来判断尖峰是否为等间距分布(或者为等间距的整数倍,因为可能会有部分特征条纹缺失),符合等间距的尖峰认为是有效峰值,不符合等间距的尖峰认为是噪音峰值,记录噪音峰值的数量 num ,若 $num > 1$,则继续进行降噪处理,直到 $num \leq 1$ 。

值得注意的是,这里的等间距不应该是绝对的,因为实际工程中并不一定所有的特征距离 d_i 都完全相等。因此这里认为若某个距离满足条件

$$d \times a - 2 < d_i < d \times a + 2 \quad (a = 1, 2, 3 \dots) \quad (3)$$

则该距离是有效的,其中 d_i 为某次计算的特征距离, d 为标准距离。通过这种方法对信号进行处理,即使有部分故障特征条纹缺失,也可以得到较好的降噪效果。

2.4 信号强度叠加折线图的评价指标

根据以上的分析可以发现,故障特征在信号强度叠加折线图中通过有效峰值展现,对于一个信号强度叠加折线图希望尽可能的识别出来更多的有效峰值,因此这里使用有效峰值数目来评价信号强度叠加折线图,认为有效峰值的数目越大,该折线图对于故障特征的展现效果越好。

遗憾的是,有效峰值数目只能作为一个评价指标,并不能作为判断故障的依据,因为通过实验发现,少量正常的信号仍然可以通过这种方法计算出来较多的有效峰值数量,这就就会发生误判。

根据以上提出的基于峰值高度的自适应循环降噪算法,可以对信号强度叠加折线图进行降噪,进一步计算出来评价指标。

3 时频图的最佳区域选取

3.1 图像分割概述

之前的实验中是人为的选取了计算区间为 $[40, 220]$,

但是对于不同的故障信号,其条纹特征的分布是不同的,如果使用固定的计算区间,必然会造成一部分信号的特征不能被很好的提取出来,因此应该针对每一个信号的时频图计算其对应的条纹分布区域,从而得到最优信号强度叠加折线图,也就是对时频图进行分割,分割出来最佳的区间。

传统的图像分割方法包括基于阈值的图像分割、基于边缘的图像分割、基于区域的图像分割、基于聚类的图像分割等。其中基于阈值的图像分割是指设定一个确定的阈值,通过对比图像中像素点的灰度值来分割图像;基于边缘的图像分割是指通过检测突变来确定边缘,以此来分割不同的区域;基于区域的图像分割通过区域增长或区域分裂合并来实现;超像素图像分割法指的是将原像素级图像根据某种特征划分成区域级图像^[16]。针对这些方法,近些年来也提出了一系列改进措施来改善其分割效果^[17-20]。不过对于时频图来说,特征分布是离散的纹理并没有边界可言,而且图片中含有大量噪音,以上所叙述的方法并不适用。

为应对图像分割场景日益复杂化的挑战,一系列基于深度学习的图像语义分割方法被提出,实现了更加精准且高效的分割,使得图像分割的应用范围得到了进一步的推广^[21]。不过这种方法需要进行大量的数据标记工作,并且使用起来非常麻烦,本文提出了一种大小可变的滑动窗口方法来实现图像分割。

3.2 滑动窗口寻找最佳区间

为了寻找条纹分布的区间,得到最优的信号强度叠加折线图,提出一种滑动窗口的方法。如图8所示设置一个高度为50的窗口,从图片的顶部向底部移动,矩形框为窗口的初始位置,虚线矩形框为窗口第一次移动后的位置,步长为10。这里的步长如果设置过大,会错过最优区间,如果设置的过小,会增加不必要的计算量。




图8 滑动窗口示意图

每次截取之后,对选中的区间进行计算得到折线图,然后再根据之前所提出的评价指标,计算折线图降噪后有效峰值的数量。每滑动一次窗口计算一次有效峰值数量、峰值之间的标准间距 d ,并且计算其对应的区间,一直计算到图片的底端。最后对记录的有效峰值数目进行排序,选取出来最佳的区间。如表1所示为图8所示的信号经过实验后得到的数据记录,可以看到当区间为 $[91, 141]$ 时可以得到最多的有效条纹,因此当窗口高度为50时区间 $[91, 141]$ 是该信号对应的最佳区间。

表1 滑动窗口实验数据记录

有效条纹数目	间距	区间
1	94	1~51
1	90	11~61
0	239	21~71
0	272	31~81
2	136	41~91
1	34	51~101
16	17	61~111
17	17	71~121
16	17	81~131
18	17	91~141
16	17	101~151
16	17	111~161
1	153	121~171
1	153	131~181
1	83	141~191
1	89	151~201
1	103	161~211
1	59	171~221
1	84	181~231
0	167	191~241
1	34	201~251

3.3 自适应滑动窗口检测算法

通过滑动窗口的方法在一定程度上可以找到较好的区间来提取出故障特征,但是这个方法也有一定的缺陷,窗口是固定不变的。上述的实验中窗口高度选取为50取得了较好的效果,但不同的数据故障特征条纹长度是不同的,如图2所示的故障信号时频图很显然条纹长度较大,窗口高度选取为50是不合适的。因此提出一种自适应选择窗口高度的方法。

自适应选择窗口高度就是窗口高度是可以变化的,变化的范围是 $[50, 200]$,每次变化的值为10。窗口高度每变化一次,都需要计算一次该窗口对应的最佳区间,并且记录本次滑动窗口的高度及其对应的本次有效峰值数目最大值;最后对不同窗口高度对应的有效条纹数目最大值进行排序,得到整体的有效峰值数目最大值就可以得到最佳区间,以此得到最优的信号强度叠加折线图。

4 实验验证

4.1 实验数据及其预处理

使用声音采集阵列来采集地铁车轮轴承的声音信号,阵列有效长度为300英寸,采集板型号为iDSC 1816,采样频率为76 800 Hz。选取的故障信号采样点数为30 243,时域图如图9所示,含大量噪音并且无法辨别故障特征。




图 9 故障信号的时域波形图

首先对原始信号进行短时傅里叶变换,得到信号的时频图,选取窗函数为 Blackman 窗、窗口长度 256、重叠样本数为 192、变换点数为 512,可以得到如图 10 所示的时频图,时频图矩阵大小为 257×469 ,时频图中的纵向条纹为故障特征。故障特征表现的不够明显且这种表现形式不容易进行计算与识别,需要进行进一步特征提取。




图 10 故障信号的时频图

4.2 计算故障分布区域


使用自适应滑动窗口检测算法对图 10 的时频图进行遍历。其中窗口的变化的范围是 $[50, 200]$,每次变化的值为 10。如表 2 所示为自适应滑动窗口检测算法计算后得到的数据记录,可以得到最优窗口高度为 60,条纹的分布区间为 $[81, 141]$ 。

表 2 自适应滑动窗口实验记录


窗口长度	有效值	区间
50	15	71~121
60	17	81~141
70	6	21~91
80	13	31~111
90	6	1~91
100	4	91~191
110	11	101~211
120	11	101~221
130	10	111~241
140	11	101~241
150	2	101~251
160	2	91~251
170	1	61~231
180	2	21~201
190	2	51~241
200	2	51~251

4.3 轴承故障特征提取效果展示

对最佳区间 $[81, 141]$ 内的时频图进行纵向叠加计算,得到该区间对应的最优信号强度叠加折线图。如图 11 所示为该信号的信号强度叠加折线图与最优信号强度叠加折线图对比图,可以看到如果直接对时频图计算得到信号强度叠加折线图如图 11(a)所示,信噪比小、故障特征微弱,折线图中难以辨别出来故障特征;而使用自适应滑动窗口检测算法得到的最优信号强度叠加折线图,如图 11(b)所示,其有效峰值突出,故障特征表现明显。



(a) 故障信号的信号强度叠加折线图



(b) 故障信号的最优信号强度叠加折线图

图 11 结果对比图

最终得到的最优信号强度叠加折线图不仅有效提取出了故障特征,而且数据量非常小,本例中最优信号强度叠加折线图长度为 469,无论是与原信号还是原信号的时频图对比,该结果数据量明显缩减,便于进行之后的计算。

5 结 论

本文针对地铁车轮轴承的声学故障诊断中背景噪声大、难以提取出有效故障特征的问题,提出了一种在强噪声背景下故障特征提取的方法。对故障信号进行短时傅里叶变换可以得到含条纹特征的时频图,条纹就是故障特征;提出一种基于峰值高度的自适应循环降噪算法对信号强度叠加折线图进行降噪,得到该折线图的评价指标为有效峰值数目;提出一种自适应滑动窗口检测法来截取时频图中条纹分布的区域,以此来得到最优的故障特征展现效果。实

验结果表明,所提出的方法可以从采集的音频信号中提取出来明显的故障特征,并且表示形式更加轻量化,不过整体算法比较复杂,未来可以改进算法结构,进一步加快计算速度。

参考文献

- [1] 李舜酩,侯钰哲,李香莲.滚动轴承振动故障时频域分析方法综述[J].重庆理工大学学报(自然科学),2021,35(10):85-93.
- [2] 洪腾蛟,丁凤娟,王鹏,等.深度学习在轴承故障诊断领域的应用研究[J].科学技术与工程,2021,21(22):9203-9211.
- [3] 关晓艳,李亚,肖杨,等.基于VMD多尺度散布熵和VPMCD的滚动轴承故障诊断方法[J].化工自动化及仪表,2021,48(4):346-352.
- [4] 陈鹏,赵小强.基于优化VMD与改进阈值降噪的滚动轴承早期故障特征提取[J].振动与冲击,2021,40(13):146-153.
- [5] 朱群伟,朱丹宸,张明悦.基于改进变分模态分解的滚动轴承弱故障特征提取[J].机电工程技术,2021,50(6):270-275.
- [6] 李翠省,廖英英,刘永强.基于EEMD和参数自适应VMD的高速列车轮对轴承故障诊断[J].振动与冲击,2022,41(1):68-77.
- [7] 陈剑,夏康,黄凯旋,等.基于VMD相对能量熵和自适应ARMA模型的轴承性能退化趋势动态预警[J].电子测量与仪器学报,2020,34(8):116-123.
- [8] 刘立,朱健成,韩光洁,等.基于1D-CNN联合特征提取的轴承健康监测与故障诊断[J].软件学报,2021,32(8):2379-2390.
- [9] 孔子宇,王海瑞.基于Inception-ResNet模型的轴承故障分类[J].电子测量技术,2021,44(5):55-62.
- [10] 王琦,邓林峰,赵荣珍.基于改进一维卷积神经网络的滚动轴承故障识别[J].振动与冲击,2022,41(3):216-223.
- [11] 陈晓雷,孙永峰,李策,等.基于卷积神经网络和双向长短期记忆的稳定抗噪声滚动轴承故障诊断[J].吉林大学学报(工学版),2022,52(2):296-309.
- [12] 赵志宏,李乐豪,李晴.一种轴承故障诊断的多任务深度学习学习方法[J].电子测量与仪器学报,2021,35(12):108-115.
- [13] 赵小强,张亚洲.利用改进卷积神经网络的滚动轴承变工况故障诊断方法[J].西安交通大学学报,2021,55(12):108-118.
- [14] 张珂,王竞禹,石怀涛,等.基于CNN的变工况滚动轴承故障诊断研究[J].控制工程,2022,29(2):254-262.
- [15] 徐文校,张银胜,杨山山,等.基于广义S变换和迁移学习的轴承故障信号的识别算法[J].电子测量技术,2021,44(24):161-168.
- [16] 焦翠玲,王顺岗,张延迪,等.基于超像素的农作物病害图像分割方法研究[J].河南科技学院学报(自然科学版),2021,49(3):58-63.
- [17] 贺航,马小晶,王宏伟,等.基于改进麻雀搜索算法的森林火灾图像多阈值分割[J].科学技术与工程,2021,21(26):11263-11270.
- [18] 秦宇幸,羿旭明.结合显著性和边缘信息的水平集图像分割方法[J].图学学报,2021,42(5):738-743.
- [19] 张宇豪,徐磊,白一清.基于条件约束的区域生长法耳蜗MR图像分割[J].电子测量技术,2021,44(8):105-109.
- [20] 刘俊,吕芳,薛海鹏.结合高斯核与各向异性邻域抑制的模糊聚类图像分割[J].电子测量技术,2020,43(3):132-138.
- [21] 黄鹏,郑淇,梁超.图像分割方法综述[J].武汉大学学报(理学版),2020,66(6):519-531.

作者简介

贾鑫,硕士研究生,主要研究方向为故障诊断。

E-mail:1973963314@qq.com

梅劲松,副研究员,主要研究方向为无人飞行器控制、嵌入式系统、无损检测系统、检测技术与自动化装置。

E-mail:jimei@nuaa.edu.cn