

基于自适应降噪的柱塞泵故障音频特征提取方法

李 炜¹ 刘 禹² 李立刚² 周 亮¹ 宋长山¹

(1. 中国石油化工股份有限公司胜利油田分公司技术检测中心 东营 257000;

2. 中国石油大学(华东)海洋与空间信息学院 青岛 266580)

摘 要:为了增强柱塞泵在强背景噪声下的音频信号特征,进而提高故障诊断准确率,提出了一种基于自适应降噪的柱塞泵故障音频特征提取方法。通过引入了 Gammatone 倒谱变换进行特征的初步提取,将柱塞泵音频信号转化到时频域,并提出一种自适应降噪方法,去除了时频信号中与故障无关的背景噪音。最后通过 Resnet-18 神经网络开展了故障分类对比实验,结果表明,经过自适应降噪,柱塞泵故障诊断准确率提高至 96.97%,验证了所提出的特征提取方法能够有效降低柱塞泵背景噪音的影响,从而提高了故障诊断的准确率。

关键词:柱塞泵;故障诊断;音频信号;信号降噪;神经网络

中图分类号: TH322 **文献标识码:** A **国家标准学科分类代码:** 510.403

Audio feature extraction method for plunger pump fault based on adaptive noise reduction

Li Wei¹ Liu Yu² Li Ligang² Zhou Liang¹ Song Changshan¹

(1. Sinopec Shengli Oilfield Branch Technical Testing Center, Dongying 257000, China;

2. College of Oceanography and Space Informatics, China University of Petroleum (East China), Qingdao 266580, China)

Abstract: To enhance the audio signal features of plunger pump under strong background noise and improve the accuracy of fault diagnosis, a method for extracting the fault audio features of the plunger pump based on adaptive noise reduction is proposed. By introducing the Gammatone cepstral transform to extract the features, the audio signal of the plunger pump is transformed into the time-frequency domain. Meanwhile, an adaptive noise reduction method is proposed to remove the background noise irrelevant to the fault in the time-frequency signal. Finally, a fault classification comparison experiment is carried out through the Resnet-18 neural network. The results show that the fault diagnosis accuracy of the plunger pump is improved to 96.97% after adaptive noise reduction, which verifies that the proposed feature extraction method can effectively reduce the influence of the background noise of the plunger pump, and improve the fault diagnosis accuracy.

Keywords: plunger pump; fault diagnosis; audio signal; signal noise reduction; neural networks

0 引 言

往复式柱塞泵是一种关键的液压设备,被广泛应用于工业生产和日常生活。在柱塞泵的运维过程中,为了能够及时发现柱塞泵存在的故障,许多学者对柱塞泵故障诊断方法进行了研究^[1]。目前,主流的柱塞泵故障诊断方法大多是基于柱塞泵的振动信号开展的^[2]。这类方法虽然已经取得了较好的效果,但通常需要安装多个传感器,且安装的振动传感器为接触式测量^[3],柱塞泵的高强度振动会

引起大量的发热,对传感器寿命造成一定的影响。因此,使用振动传感器进行大规模监测部署时,以上问题会在无形中增加柱塞泵的运维成本。

通过音频信号进行监测是一种新型故障诊断技术^[4-5],具有非接触式测量、传感器数量较少等优势,设备部署成本更低。目前,已经被应用于列车门^[6]、变压器^[7]和滚动轴承^[8]等设备的故障诊断研究中。在柱塞泵的运维过程中,经验丰富的专家能通过通过声音辨识部分故障,因此通过音频信号对柱塞泵进行故障诊断具有一定的可

行性^[9]。但由于柱塞泵在运行过程中会产生较大的背景噪音,使得故障声音容易淹没在噪音环境中,导致了音频信号在柱塞泵故障诊断中得不到广泛应用。因此,对柱塞泵音频信号进行有效降噪,提取出高信噪比的故障特征,是柱塞泵音频信号故障诊断的关键技术。

而柱塞泵由于其活塞往复运动的特点,故障声音的能量在一段时间内的变化幅度较大^[10],常规基于时域的滤波方法并不能取得良好的降噪效果。而柱塞泵的故障声音和背景噪音来源相同,二者声音的频率范围相似,仅从频域也难以消除噪音的干扰。目前,基于时频域的信号降噪方法在机械设备的故障诊断中取得较好的降噪效果^[11]。马增强等^[12]将变分模态分解和独立分量分析相结合,对滚动轴承振动信号进行了联合降噪,使故障特征更加清晰。曹玲等^[13]改进了小波阈值降噪,有效提高了滚动轴承振动信号的信噪比。何冬等^[14]提出了一种基于总变差降噪和递归定量分析的单向阀故障诊断方法,在降低背景噪声、表征故障信息和保证故障诊断准确性方面具有明显的效果。仝兆景等^[15]采用自适应噪声集合模态分解的方法对数据进行降噪处理,增加了故障诊断模型的鲁棒性。但上述方法仍然没有完全摆脱人工经验因素,如分解层数确定和部分阈值选取等问题。

为了解决上述问题,为柱塞泵音频故障诊断奠定基础,本文提出了一种基于自适应降噪的柱塞泵音频特征提取方法。通过 Gammatone 倒谱变换将柱塞泵音频信号转换到时频域,提取出音频信号的 Gammatone 声谱图,再根据所提出的自适应降噪方法除去了与故障诊断无关的背景噪音,提取出了故障清晰可辨的故障特征图。该方法无需人工选取阈值,可以自适应完成对柱塞泵音频信号的降噪和特征提取。

1 Gammatone 倒谱变换

柱塞泵的音频信号是一种一维信号,且含有较大的背景噪音,故障特征在原始信号中并不突出。由于柱塞泵的往复运动,故障的频率特征往往也会跟随其运动呈现出周期性的特点,仅从频域也不易对故障进行区分。在对机械声音信号分析时,可通过短时傅里叶变换^[16]提取出信号的声谱图,从时频域中更能直观地观察到信号的故障特征。

Gammatone 倒谱变换是在短时傅里叶变换的基础上,增加了一个 Gammatone 滤波器组,其完整的信号处理流程如图 1 所示。

其中最关键的 Gammatone 滤波器组是模仿人耳耳蜗的听觉特性而设计^[17],滤波器组的时域脉冲响应公式为:

$$g_i(t) = At^{n-1}e^{-2\pi b_i t} \cos(2\pi f_i t + \phi_i)U(t) \quad (1)$$

$$t \geq 0, 1 \leq i \leq N$$

式中: A 为滤波器的增益; f_i 是第 i 个滤波器的中心频率; $U(t)$ 为阶跃函数; ϕ_i 是相位,由于人耳对相位变化并不敏




图 1 Gammatone 倒谱变换流程

感,本文取 $\phi_i = 0$; n 是滤波器阶数,通常取 $n = 4$; N 为滤波器个数,本文取 $N = 64$; b_i 为滤波器的衰减因子,可以由等效矩形带宽 $ERB(f_i)$ 计算得出:

$$b_i = 1.019ERB(f_i) \quad (2)$$

$$ERB(f_i) = 24.7 \times \left(4.37 \times \frac{f_i}{1000} + 1 \right) \quad (3)$$

生成的 Gammatone 滤波器组能够完整覆盖人耳听觉的 20 Hz~20 kHz 频率范围,并且在低频处滤波器更精细,高频处较粗略,符合人耳对低频更加敏感的特性。滤波器组的幅频响应如图 2 所示。




图 2 Gammatone 滤波器组幅频响应

以正常工况下的柱塞泵音频信号为例,在未经额外信号处理时,生成的 Gammatone 声谱图如图 3 所示。根据实验发现,声谱图中颜色较亮的部分是柱塞泵运行时产生的主要声音成分,也是用于故障诊断的关键部分;而颜色较暗的部分在多种工况中均有出现,属于背景噪音。因此,有必要对柱塞泵的音频信号进行降噪,减少特征图中的冗余信息。

2 柱塞泵音频自适应降噪方法

经过 Gammatone 倒谱变换后,柱塞泵音频信号会转换为一个 $m \times n$ 的二维矩阵 $\mathbf{D}$,其中 m 为采样的时间点个数, n 为采样的频率点个数,矩阵中的元素 D_{tp} 代表当前时间点 t 在频率 p 处的能量。假设时频信号 $\mathbf{D}$ 由能量较强的前景信号和能量较弱的背景噪音两个部分组成,根据能量强度统计出信号 $\mathbf{D}$ 的直方图 $H(\mathbf{D})$,则应为双峰直方图。如图 4 所示,只要找到双峰之间最小值所在位置对应的信号能量,即为划分前景信号和背景噪音的最佳能




图3 柱塞泵音频信号 Gammatone 声谱图




图4 降噪能量阈值选取示意图

量阈值。

但是在实际情况中,柱塞泵音频信号的时频能量并不能很明显地分为两类,其直方图更接近于高斯分布,如图5所示。





图5 柱塞泵音频信号时频能量直方图


因此需要对时频信号进行预处理,使其能量直方图出现双峰,这一过程也是一个初步滤波降噪的过程。首先,统计得出时频信号每个时间单位 t 的最小能量 $D_{\min}^t$ 和平均能量 D_{mean}^t ,再按下式过滤信号能量较小的部分:

$$D_{t,p} = \begin{cases} D_{t,p}, & D_{t,p} \geq D_{\text{mean}}^t \\ D_{\min}^t, & D_{t,p} < D_{\text{mean}}^t \end{cases} \quad (4)$$

经过上述预处理,放大了时频信号中高能和低能部分的差距,使时频信号的能量直方图出现双峰。虽然预处理也能够滤除部分能量较弱的信号,但是由于柱塞泵音频信号在某些时刻的瞬时能量较大,使得该部分的 D_{mean}^t 偏大,仅按式(4)的预处理还无法完全滤除背景噪音,预处理结果如图6所示。



(a) 预处理后的柱塞泵音频信号 Gammatone 声谱图



(b) 预处理后的柱塞泵音频信号时频能量直方图

图6 预处理后的柱塞泵音频信号

为了定位直方图双峰之间的最小值,需要先定位双峰的位置。因此,首先定位出直方图中的所有极大值点,将各点按统计点数进行降序排序,得到的极大值点和排序如图7所示。

经过排序筛选,可以得到直方图最大的两个极大值点 $H(a)$ 和 $H(b)$, 设 $a < b$, 再通过如下公式即可得到最佳能量阈值:

$$D_{th} = \underset{D}{\operatorname{argmin}} H(D), a < D < b \quad (5)$$

最后,在预处理时频信号的基础上,再次通过最佳能量阈值进行滤波,除去信号中剩余的背景噪音,其计算公式为:

$$D_{t,p} = \begin{cases} D_{t,p}, & D_{t,p} \geq D_{th} \\ D_{\min}^t, & D_{t,p} < D_{th} \end{cases} \quad (6)$$

式中: $D_{\min}$ 为时频信号的全局能量最小值。滤波降噪后,




图7 极大值点及其排序

即可得到增强的柱塞泵音频信号特征图,如图8所示。




图8 特征增强的柱塞泵音频信号 Gammatone 声谱图

3 实验与分析

3.1 实验条件

为了验证所提出的特征提取方法能够有效提高柱塞泵故障诊断准确率,需要在柱塞泵上开展故障诊断实验。由于生产运行中的柱塞泵在短期内不易发生较多故障,需要通过在实验柱塞泵上开展破坏性实验,模拟实际运行中的故障工况。本文选用 3QP0 型高压往复柱塞泵作为实验对象,传感器采用一个 ECM888B 测量麦克风,其采样频率为 48 kHz。正常工况下,柱塞泵的出口压力为 6 MPa,往复次数为 280 min^{-1} 。通过人工对轴承、柱塞和十字头等零部件进行破坏性实验,制造出 10 种故障,分别为阀芯损坏、皮带磨损、柱塞填料密封泄露、十字头磨损、轴承外圈磨损、轴承支撑架损坏、阀座弹簧损坏、柱塞点蚀、柱塞松动和柱塞磨损。分别在正常工况和不同的故障工况下,通过一个位置固定的 ECM888B 测量麦克风,采集音频信号至笔记本电脑进行分析,柱塞泵实验平台如图9所示。

为了保证实验条件的一致,所有实验都在相同的硬件环境下开展: Intel Core i7-6700HQ 2.60 GHz CPU, 16 GB RAM, NVIDIA GeForce GTX 980 M GPU,




图9 柱塞泵实验平台

Windows 10 专业版。

3.2 柱塞泵音频信号特征提取

通过破坏性实验,分别采集到了 11 种柱塞泵状态(正常状态+10 个故障状态)下的音频信号。由于每种状态下采集到的音频信号较长,需要对其进行信号分割,并且考虑到柱塞泵的动态特性,所分割的信号应至少包含两个完整的往复周期。因此,根据柱塞泵的往复次数,将音频信号分割为 0.5 s 长度的样本。信号分割完成后,通过 Gammatone 倒谱变换提取出柱塞泵音频信号的 Gammatone 声谱图,然后通过所提出的自适应降噪方法对时频信号降噪,降噪后的 Gammatone 声谱图作为柱塞泵音频信号的特征样本。为了便于展示,选取了 4 种实际运行中较为常见的故障状态,分别为填料密封泄露、阀座弹簧损坏、十字头磨损、柱塞磨损,其信号降噪和特征提取结果如图 10 所示。




图10 柱塞泵音频信号特征提取结果

从实验中可以明显观察出,柱塞泵音频信号通过 Gammatone 倒谱变换后,其故障特征已经相比原始信号更加突出,但仍然存在较大的背景噪音。在经过自适应降噪处理后,背景噪音被有效滤除,减少了所提取的故障特征中的冗余信息,使每种故障信号之间的差异更加明显。

3.3 基于 Resnet-18 的柱塞泵音频信号故障诊断

为了验证所提出特征提取方法的有效性,分别通过短时傅里叶变换、梅尔倒谱变换、Gammatone 倒谱变换进行特征提取。同时,为了验证自适应降噪方法的有效性,再将其与 3 种特征提取方法结合,共通过 6 种特征提取方法

对11种状态下的柱塞泵音频信号进行特征提取。利用提取的特征构建6个柱塞泵故障音频数据集,并使用深度学习开展故障诊断对比实验。

由于能够采集到的故障样本数量有限,不适合选用层次较深的神经网络作为故障分类模型。综合考虑到分类器的性能,选用了Resnet-18作为故障诊断的分类模型。设置模型的学习率为0.01,批尺寸为64,使用10折交叉验证法对训练模型进行验证。实验得到的故障分类准确率对比如表1所示。

表1 柱塞泵音频故障诊断结果

特征提取方法	故障分类准确率/%
短时傅里叶变换	82.04
梅尔倒谱变换	89.35
Gammatone 倒谱变换	91.29
自适应降噪+短时傅里叶变换	84.56
自适应降噪+梅尔倒谱变换	90.29
自适应降噪+Gammatone 倒谱变换	96.97

根据实验结果可以看出,通过3种时频变换方法提取出的柱塞泵音频特征,与自适应降噪方法结合后,故障分类准确率都得到了提升。其中自适应降噪结合Gammatone倒谱变换的方法,取得了最高的故障分类准确率,高达96.97%。综上所述,本文所提出的自适应降噪方法减少了柱塞泵音频信号的背景噪音,再结合Gammatone倒谱变换进行特征提取后,有效提高了柱塞泵故障诊断准确率。

4 结 论

本文针对柱塞泵背景噪声大,难以通过音频信号开展故障诊断的问题,提出了一种基于自适应降噪的柱塞泵故障音频特征提取方法。该方法利用Gammatone倒谱变换将柱塞泵音频信号转换到时频域,并通过所提出的音频自适应降噪方法,在时频域完成了信号降噪。实验结果表明,该方法在有效提取柱塞泵音频故障特征的同时,去除了柱塞泵音频信号中不利于故障诊断的背景噪音,从而有效提高故障诊断的准确率,为柱塞泵音频信号故障诊断提供了技术支持。

本文提出的基于自适应降噪的柱塞泵故障音频特征提取方法能有效提高柱塞泵的故障诊断准确率,对实际运行中的柱塞泵故障诊断有一定指导意义。但是本文仅研究了实验用柱塞泵,后续研究工作中将针对实际运行中的柱塞泵进行长期实验和进一步扩展。

参 考 文 献

[1] 杜振东,赵建民,李海平,等.基于SA-EMD-PNN的柱塞泵故障诊断方法研究[J].振动与冲击,2019,38(8):145-152.

[2] 赵立红,程珩,励文艳,等.LMD样本熵与SVM结合的柱塞泵故障诊断研究[J].机械设计与制造,2022(3):238-241.

[3] 刁宁昆,马怀祥,刘锋.一种改进LeNet5结合LightGBM的滚动轴承故障诊断方法[J].国外电子测量技术,2022,41(1):140-145.

[4] 邹宜金,连应华,黄新宇,等.基于声纹的高泛化性风机叶片异常检测方法研究[J].电子科技大学学报,2021,50(5):795-800.

[5] 裴峻峰,严安,彭剑,等.声信号的MFDFA和SFLA-SVM算法的往复泵故障诊断[J].机械设计与制造,2020(4):199-203,207.

[6] SUN Y K, XIE G, CAO Y, et al. Strategy for fault diagnosis on train plug doors using audio sensors[J]. Sensors, 2018, 19(1): 3.

[7] LIN L H, LI Y, MA L, et al. Research on transformer audio fault identification method based on neural network[C]. Proceedings of 2019 International Conference on Intelligent Transportation, Big Data & Smart City (icitbs 2019), Conference Publishing Services, 2019: 629-632.

[8] 孙萧,黄民,马超.基于CEEMD和WOA_LSSVM滚动轴承声信号故障诊断[J].组合机床与自动化加工技术,2021,564(2):52-56,61.

[9] 梁小康.基于谱图和声学特征的旋转机械故障检测方法[J].电子器件,2021,44(3):737-740.

[10] BIE F F, HOROSHENKOV K V, QIAN J, et al. An approach for the impact feature extraction method based on improved modal decomposition and singular value analysis[J]. Journal of Vibration and Control, 2019, 25(5): 1096-1108.

[11] 刘舒沁,刘若晨,王益民,等.基于变分模态分解的静电监测信号去噪方法研究[J].噪声与振动控制,2022,42(1):119-124.

[12] 马增强,柳晓云,张俊甲,等.VMD和ICA联合降噪方法在轴承故障诊断中的应用[J].振动与冲击,2017,36(13):201-207.

[13] 曹玲玲,李晶,彭镇,等.基于改进小波阈值降噪的滚动轴承故障诊断方法[J].振动工程学报,2022,35(2):454-463.

[14] 何冬,黄国勇,钱恩丽,等.基于总变差降噪与RQA的单向阀故障诊断[J].电子测量与仪器学报,2021,35(2):65-72.

[15] 仝兆景,李金香,乔征瑞,等.基于改进贝叶斯网络的电机轴承故障诊断[J].电子测量技术,2022,45(7):

- 48-55.
- [16] VERSTRAETE D, FERRADA A, DROGUETT E L, et al. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings[J]. Shock and Vibration, 2017, DOI: 10.1155/2017/5067651.
- [17] 林海波, 王可佳. 一种新的听觉特征提取算法研究[J]. 南京邮电大学学报(自然科学版), 2017,

37(2):27-32.

作者简介

李炜, 硕士, 高级工程师, 主要研究方向为电力节能技术。

刘禹(通信作者), 硕士研究生, 主要研究方向为智能信息处理、柱塞泵故障诊断。
E-mail: liu_yu3@qq.com