

DOI:10.19651/j.cnki.emt.1802215

基于谱聚类分析的托辊故障诊断

宋天祥¹ 杨明锦¹ 杨林顺² 张明明² 彭晨¹

(1.上海大学机电工程与自动化学院 上海 200072; 2.西山煤电(集团)有限公司屯兰选煤厂 太原 030206)

摘要: 有效地诊断托辊故障,对提高选煤工作效率和工厂智能化水平具有重要的作用。针对工业现场环境复杂,噪音类型多且杂的特点,首先提出利用差分法来消除托辊音频序列数据时间趋势影响的有效方法,在此基础上提取托辊音频序列特征,分别利用 K-Means 和谱聚类算法进行聚类分析以及故障识别,并从噪音音频序列数据中挖掘有用的信息。然后为了评价聚类模型的优劣,创新提出将同一音频序列分割得到子音频序列的相同聚类标签的平均比率,以此作为聚类优劣的评判标准。实验结果表明,谱聚类算法的效果优于 K-Means,动态选取谱聚类的参数值能够提高局部诊断准确率,且具有较强的鲁棒性,能够实现对生产范围内多种类型噪音音频信号进行有效聚类识别。智能化托辊故障诊断系统的应用提高了选煤工作效率,减少了非计划停机次数,产生了较好的经济效益。

关键词: 托辊故障; K-Means; 音频时间序列; 故障诊断; 谱聚类

中图分类号: TH17; TN911.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

Fault diagnosis for roller based on spectral clustering analysis

Song Tianxiang¹ Yang Mingjin¹ Yang Linshun² Zhang Mingming² Peng Chen¹

(1.College of Mechatronics Engineering and Automation, Shanghai University, Shanghai 200072, China;

2.Coal Preparation Plant of Tunlan, XiShan Coal and Electrical limited company, Taiyuan 030206, China)

Abstract: Valid roller fault diagnose plays an important role in improving working efficiency and intelligent plant. In view of complex industrial environment and numerous noise types, first, a difference method is used to eliminate the influence of time trend in audio sequence data, and to extract the characteristics of the roller audio sequence. Secondly, K-Means and spectral clustering algorithms are used to have cluster analysis and roller faults identification. In order to evaluate advantages and disadvantages of proposed clustering model, an average ratio of sub-sequence same labels from an audio sequence is proposed to achieve the above aim. Experimental results show that local diagnostic accuracy can be improved by dynamic selection of parameter values. Roller fault can be effectively identified and diagnosed by two proposed clustering algorithms, but spectral clustering algorithm is superior to K-Means algorithm. By use of the proposed methods, one can see that the efficiency of coal preparation is improved, number of unplanned outages is reduced, and good economic benefits are also produced.

Keywords: roller fault; K-Means; audio time series; fault diagnosis; spectral clustering

0 引言

针对选煤厂托辊故障诊断问题,单纯依靠传统的故障诊断方法已经不能满足实际要求。其原因在于一方面,传统的故障诊断主要依赖于人工,易对工人身体造成不可逆转的伤害;另一方面,由于选煤厂设备大型化和复杂化的发展趋势,使得传统人工诊断方法不能有效地对复杂故障做出精准判别。因而研究具有智能化的托辊故障诊断系统更符合实际应用。

机械故障的智能诊断方法主要通过工作时产生的振动信号或音频信号进行分析来判断其运行状态^[1]。其中振动

信号法须将传感器安装在设备适当的位置以获取信号,该方法成本高且使用不便。音频信号的采集具有非接触性,使用方便,成本低^[2]。当设备发生故障时,其噪声特征也会发生改变,因此噪声中含有大量设备运行状态的信息^[1]。

音频信号的分析方法主要有监督识别^[3]和无监督聚类^[4]两类。无论采用哪类方法,都需要首先对音频信号提取特征参数。音频特征参数的提取主要从时域、频域以及通过经验模式分解与独立分量分析联合处理的盲源信号分离等方面出发^[5-7]。时域方面主要通过振幅的采集作为判断依据,频域方面主要通过频带宽度分析作为故障诊断的

依据。常被选用的特征有感知线性预测、基频、梅尔频率倒谱系数和过零率等,或者这些特征的组合。

在信号的监督识别方面,常用的分类器有 Gaussian 混合模型、隐马尔可夫模型、支持向量机(support vector machine, SVM)、深度神经网络等。Zhang 等^[8]计算振动信号的排列熵来检测轴承故障,Guo 等^[9]利用带有二叉树识别策略的支持向量机来对音频进行分类,Dhanalakshmi 等^[10]利用 SVM 结合径向基神经网络对音频自动分类,Davy 等^[11]应用 SVM 来检测音频频谱突变,从而对音频信号进行分割, Lee 等^[12]应用隐马尔可夫模型对波形特征提取后进行机械故障诊断,Tüske 等^[13]对输入的丰富信息经深度神经网络非线性变换得到深层特征,从而进行分类。

在无监督聚类方面,李志农等^[14]提出一种基于经验小波变换的机械故障诊断方法,并通过实验验证该方法的有效性,Kotti 等^[15]将贝叶斯信息准则作为收敛准则实现凝聚分层聚类算法,对常见音频信号进行聚类,张宇献等^[16]为了解决传统聚类算法处理混合属性以及聚类可视化问题,提出了基于异均值差度量的自组织映射混合属性数据聚类算法,张焱等^[17]利用谱聚类为非负矩阵分解产生结构化初始值,有效提升了非负矩阵分解收敛性问题的收敛效果与分解性能,并提高诊断精度,Von 等^[18]介绍了最常见的谱聚类算法,并讨论了不同谱聚类算法的优缺点。

皮带运输机通过上下两个功率为 12 kW 的电机提供动力,在皮带运行时,皮带运输机上煤质的质量实时变化,传输速度相应地也会实时变化。现场采集的噪音音频与皮带传输速度有关,因此采集的信号周期是时变的。故障噪音的音量、持续的时长也会受到传送带输煤质量的影响而实时变化。工业现场采集到音频事件类型多且相互之间有干扰,即故障与征兆之间不存在简单的一一对应关系^[19]。准确识别出音频中包含的信号类型进行故障诊断难度大且需要大量的无污染样本,这在采样环节难以实现。对实际工业应用来说,意义也不大。

本文通过对工业现场音频数据的时域特征提取,利用谱聚类对噪音信号进行归类,聚类分析结果可以得到严重故障报警信号和初步故障报警预防信号,以此来实现对现场设备的实时监控,保证设备高效运行。本文首次将谱聚类算法用于对工业现场噪音进行聚类,创新提出将同一音频序列分割得到子音频序列的相同聚类标签的平均比率作为聚类算法优劣的评判标准,实际应用说明了方法的有效性。

1 音频特征提取

由于工业现场生产环境复杂且多变,从工业现场采集到的噪音音频进行解析得到的数据,无论是数据量还是数据的数值变化范围都很大,包含了大量无关的信息,因此,需预处理去除噪音音频时间序列中的趋势,在此基础上进行噪音音频特征提取。

1.1 音频时间序列数据预处理

现场直接采集到的音频数据具有复杂性、模糊性和随机性,同时蕴含规律性,可以将它看成是时间序列数据。音频时间序列数据包含波形值随时间变化的趋势,序列中的趋势随时间推移发生规律变化。建模、识别趋势信息,并去除其影响,对故障诊断是非常重要的^[20]。

皮带运行产生的噪音是监测信号的主要来源,同时还会有电机噪音和背景环境噪音的影响。当故障产生后,噪音会发生明显变化。现场采集的音频数据解析后,如图 1 所示,图为任意选取的 3 个不同位置音频样本的数据波形。




图 1 噪音音频信号波形(不同位置音频序列的波形)

从图 1 可以看出,噪音数据波动范围较大,直接进行特征提取,则面临计算量大,难以获取有用特征。因此,需要去除趋势的影响再进一步进行提取特征。本文尝试多种模型来去除时间趋势,主要介绍差分模型、线性模型和正弦函数模型去除趋势的影响。

差分法是在等时间步长的基础上,计算前一观察点和当前观察点的差,来构造新序列。线性模型法根据时间与噪音数值的关系生成预测线,作为原音频数据的趋势线,通过计算原始值与预测值之间的差值生成新的序列。正弦函数法是将时间与噪音数值的趋势信息利用正弦函数进行拟合,而后将拟合值与原音频信号作差,得出新序列。3 种方法对音频时间序列去除趋势所得结果如图 2 所示。




图 2 消除时间趋势后的噪音数据图

由于噪音音频波形的幅值变化明显、周期不稳定,采用线性模型不能有效去除趋势的影响,消除趋势后的音频波形和原始音频波形差异不大。正弦模型会使得某些有用特征变得不明显,且幅值仍在较大范围内变化,亦不能有效去除趋势的影响。采用简单的差分法反而能够较好实现去除时间趋势。

对比而言,选用差分法能将噪音音频数据的波动范围缩减到较小的范围内,数据中仍然包含设备故障信息。因此,在此基础上,对差分后的音频数据进行特征提取。

1.2 音频故障特征提取方法

Ouyang 等^[21]通过利用时间序列的平均值、最大值、振幅和标准差作为时间序列的特征,对水利发电时间序列进行聚类,发现其中蕴含的知识。受此启发,本文对消除趋势后的时间序列进行故障特征提取。

故障产生时峰值变化较大,峰值不受皮带转速影响,故障信息可以通过峰值方便地检测出来。噪音音频峰值易受周围环境影响,单纯选用噪音音频峰值对托辊故障诊断意义不大。

根据现场经验以及对比多组噪音音频信号预处理后的数据信息如图 3 所示,可知托辊断裂的音频序列数据包含大量高频、高峰值的数据信息。因此,结合故障音频数据的特性,选用消除趋势后数据中的某个频率和幅值作为阈值,统计符合要求的波形数量作为特征。




图 3 正常运行和托辊断裂的音频序列对比

经多组实验对比,阈值选取周期 0.12 ms,峰值 2 000 作为准则来统计波形数量,该准则能够将现场采集到的音频信号分为正常信号和故障信号两类。

该分类结果误判率高,如机头位置处的噪音音频序列大都被归为故障一类,生产过程中因皮带跑偏产生摩擦干扰的噪音音频序列也会被归为故障信息,部分故障信息也会因高频分量不够明显被归类错误等。该判别标准界限模糊,不能精确地诊断故障,且分类过于简单,不符合生产需求,因而考虑将其作为故障诊断的一个特征用于进一步聚类分析。

托辊偏心时,故障音频波形的峰值相较于正常信号差

异不大,均方差变化也不大,但为了提高生产效率、减小损失,仍应尽早检测出此类故障的发生,以便提前修复。在电机故障诊断中,主要通过峭度指标来识别故障初期的音频时间序列^[22]。在此利用峭度特征对因托辊偏心的故障进行诊断。峭度指标通常用峭度系数的大小来衡量。峭度系数是归一化的四阶中心矩,用于反应振动信号的分布特性。数学表达式为:

$$K_x = \frac{E(x - \mu)^4}{\sigma^4} = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i}{\sigma} \right)^4 \quad (1)$$

式中: K_x 为原始信号线 x 的峭度系数; N 为信号的长度; μ 信号 x 的均值; σ 信号 x 的标准差。正常信号峭度值近似为 3,故障不断发展时,峭度值则会变大。

此外,本文计算去除时间趋势后音频序列的均值和方差值做为特征向量,进一步对噪音音频聚类。

2 故障诊断聚类算法

首先根据阈值信息作为判别准则将信号简单分为两类,类别界限不明显且误判率高。因此尝试聚类算法来进一步分析。

聚类算法是根据同类样本间具有高相似性,不同类样本间有很大的不同,从而将数据分为多个类别的过程。聚类算法是一种无监督学习算法,相较于分类来说,聚类算法不需要预先知道训练数据的类别,对类别界限不明显的数据集有较好的效果。

托辊正常运行时,噪音波形会被限制在一定范围内变化。托辊故障的噪音波形波动剧烈程度远超过正常运行的噪音波动范围,但机械干扰和托辊故障的噪音音频序列变化趋势相类似,难以直观地对采集到的噪音音频序列按照某个准则进行分类。因此,利用聚类算法来处理该问题。

本文首先尝试采用 K-Means 算法,将空间中的数据以 k 个点为中心进行聚类,根据样本与中心点的最小距离进行归类。获取新样本后,更新聚类中心的数值,逐次迭代,直至聚类中心的值不再变化为止^[23]。该算法的详细描述如下:

1) 随机选取 k 个聚类中心, $\mu_1, \mu_2, \mu_3, \dots, \mu_k \in R^n$ 。

2) 对于每一样例 i , 根据式(2)计算其与聚类中心的距离判别其归属的类。

$$C_j = \operatorname{argmin}_j \|x^{(i)} - \mu_j\|^2 \quad (2)$$

3) 得到新样本后按照式(3)更新质心。

$$\mu_j = \frac{\sum_{i=1}^m 1\{c^{(i)} = j\} x^{(i)}}{\sum_{i=1}^m 1\{c^{(i)} = j\}} \quad (3)$$

式中: $c^{(i)} \in [1, k]$ 是样例 i 所属的类; μ_j 是质心,代表同类样本的中心点。

4) 重复上述过程,直至质心不变或变化很小为止。

K-Means 算法实现简单,复杂度较低,对很多简单问

题都能得到令人满意的结果。K-Means 算法的结果经常会收敛于局部最优解,不能保证类内距离为最小值,而且如果 K 值与实际问题偏差较大,则很难获得好的结果。

其次采用谱聚类算法。该算法是一种基于图论的算法,与其他聚类算法不同的是谱聚类将聚类问题转化为图分割问题。以分割代价最小为目的,将单一样本组成的无向加权图划分为多个子图,如图 4 所示,从而实现聚类^[17]。




图 4 谱聚类中图的分割

谱聚类的具体步骤如下:

1) 将原问题转化为图,使用 k -nearest neighbor graph 将每个点与最近的 k_{knn} 个相似度最高的点连边。

2) 根据式(4) k -nearest neighbor 相似度矩阵,计算式(5)拉普拉斯矩阵。

$$W_{ij} = W_{ji} = \exp\left(-\frac{\|x_i - x_j\|_2^2}{2\sigma^2}\right) \quad (4)$$

$$f^T L f = f^T D f - f^T W f \quad (5)$$

式中: D 为度矩阵,是一个对角矩阵,主对角线各元素对应第 i 行 i 列点的度数。

3) 计算拉普拉斯矩阵的特征向量,得出 k_{knn} 个最小特征值所对应的特征向量。

4) 利用 K 均值对该 k_{knn} 个特征向量进行聚类。

谱聚类是常用的聚类算法,相比于 K-Means 算法,谱聚类对数据分布的适应性更强,聚类效果也很优秀,同时聚类的计算量也小很多,实现起来也很方便。在解决托辊故障诊断问题中,谱聚类的子图概念也可以很好地与切割前的原始音频序列相映射。

3 实验与结果分析

3.1 实验介绍

在 Python 3.6 环境下,自主开发了基于谱聚类的托辊故障诊断系统,本文所有实验均是在此平台上完成。

智能化托辊故障诊断流程如图 5 所示。通过传感器对工业生产现场的噪音音频序列实时采集、建模和分析,根据分析结果做出相应提示,以便相关人员及时对设备检修维护,所用传感器模块如图 6 所示。




图 5 智能化托辊故障诊断流程



图 6 传感器模块

为了保证算法的鲁棒性,噪音音频样本包括皮带运煤以及皮带空载下各类型音频。采样共得到 80 组音频录音,采样频率为 44 100 Hz,每段原始录音的时长为 20 s。为避免采样时的人为干扰,将 20 s 的噪音音频信号去除前 3 s 和后 3 s,进行均等切分,得到 800 组样本长度为 1 400 ms 的有效音频数据,每段音频信号解析出来有 60 000 多个样本点。智能化托辊故障诊断算法流程如图 7 所示。




图 7 智能化托辊故障诊断算法流程

消除时间趋势后,音频波动范围明显减小,便于时序特征提取。对去除时间趋势后的信号波形进行特征提取,选取的特征包括超出设定阈值的波形数量、波形均值、标准差和峭度,接下来分别利用 K-Means 和谱聚类算法进行聚类。

为了避免某一类样本的特征偏差过大对实验结果的准确率产生不利影响,实验首先利用 K-Means 算法对音频序列进行初步诊断识别,而后调整各类样本数量,使各类样本比例相差不大。经筛选,实验数据包括 40 组不同序列产生的 400 个样本,聚类结果应将同一段音频产生的 10 个样本尽可能多的归为一类,计算每组样本准确率的均值作为评判标准来选择参数,并对比算法效果。

按式(6)计算所得准确率。如果有两类或多类标签比重一样,则将其归为故障等级较高的一类。分别选取聚类簇数为 2、3、4、5、6 类进行实验。

$$r = \frac{1}{40} \sum_{i=1}^{10} \frac{m_i}{n_i} \quad (6)$$

式中: r 表示准确率; m_i 表示由同一段音频产生且聚类标签一致的子音频序列数量; n_i 表示由同一段音频产生的子音频序列的总数。

针对不同的聚类簇数,K-Means 和谱聚类的实验结果对比结果如图 8 所示。

3.2 实际实验

通过图 8 所示的实验结果准确率可以看出,谱聚类的




图 8 类别数和准确率的关系

结果要优于 K-Means 的聚类结果。聚类结果为 2 类时, K-Means 和谱聚类都获得最好的聚类结果, 但该情况仅仅将故障类型分为正常信号和故障信号两个类别。故障信号中包含有大量干扰信号, 该类信号会对故障诊断结果产生严重误判, 不符合实际生产应用。

噪音音频的聚类结果分为 4 类符合理论分析和实际应用, 因而, 以此作为故障诊断报警的依据。诊断分析得到的故障分级结果如表 1 所示。

表 1 基于谱聚类分析的故障分级结果

类别	噪音类型	故障等级	采取措施
1	托辊断裂噪音	非常严重	立即维护
2	托辊严重偏心、改向滚筒与驱动滚筒螺栓松动的噪音	严重	停工后检修
3	设备正常运行的噪音以及摩擦等干扰的噪音	正常	无需处理
4	进煤口和出煤口的噪音	正常	无需处理

第 1 种类型信号为托辊断裂噪音信号, 此类故障情形最为严重, 是最需要识别的故障。该类故障发生时应及时处理, 以避免引发更大故障。以往的人工巡检, 不能够及时发现此类故障, 因而常常会造成故障的影响扩大。第 2 种类型为托辊偏心, 改向滚筒与驱动滚筒螺栓松动产生的噪音信号, 此类故障不会对设备产生较大影响, 可以在工厂作业完成后再去修复。在以往人工巡检中, 常对此类信号有所误判或漏检, 不能及时采取有效应对措施。第 3 种类型信号, 为设备正常运行的噪音信号, 包括皮带偏离正常轨道与调偏装置产生的摩擦噪音, 此类信号无需报警。第 4 种类型的信号为皮带前后端进煤口和出煤口的噪音信号, 此类信号的识别对进煤口和出煤口出的故障识别很有必要。

聚类簇数增大, 会对同一音序列的判别结果过于细化, 从而产生更大误差。最终选取聚类簇数为 4 类, 而设备运行状态分为正常、故障和严重故障 3 类。机头和机尾处的噪音音频并入正常信号的范围, 以消除误报警的影响。

谱聚类的故障诊断准确率高达 95.1%, 对工业现场出现的各类故障噪音信号都能有效识别, 极大提高了工业生产的智能化水平。

本文进一步研究谱聚类算法 k-nearest neighbor 中 k_{knn} 的选取对实验结果的影响, 实验以 10 为中心将聚类簇数按照 2、3、4、5、6 类分别进行实验, 所得实验结果如图 9 所示。




图 9 不同 k_{knn} 取值下谱聚类的准确率

从图 9 实验可以得出当谱聚类选取 k-nearest neighbor 中 k_{knn} 取为 10 的时候在各种情况下都会获取最好效果。随着 k_{knn} 的增加和减小, 准确率会有所降低。对各类音频分析得出, 该现象产生的主要原因是机头机尾处以及托辊故障(包括严重故障)处的噪音音频被诊断出错, 因此进一步分析 k_{knn} 变化对这些类别误诊率的影响, 如图 10 所示。




图 10 不同 k_{knn} 取值下谱聚类的误诊率

从图 10 可以看出, 如果增大 k_{knn} 的取值会对机头和机尾处噪音音频的准确率有所提高(曲线 N), 但对于故障(包括严重故障)的音频序列(曲线 F)则会有较多的误判, 其原因是托辊断裂后会间歇性地碰撞皮带, 甚至会短时卡死停转, 因而切分出来的音序列有大部分会被误判为较低级别。如果减小 k_{knn} 的取值, 对机头和机尾的噪音音频信号准确率判别会略有降低, 此时算法对现场环境干扰敏感度提高, 机头和机尾处音频变化明显, 因而造成误判, 但对严重故障噪音音频的识别准确率却会有所提高。

结合实验结果以及该智能化故障诊断系统的运行调

试,根据安装位置的环境进一步调整参数值的设定,降低误判,提高诊断的准确率。在机头机尾以及干扰多发的地方可以适当增大 k_{knn} 的取值来提高诊断准确率,检测到故障信息后可以适当降低 k_{knn} 的取值来提高故障识别的精度。在机头和机尾除进行多组故障诊断测试,结果显示倘若机头、机尾存在故障,噪音音频会被自动归为故障的类别。智能化托辊故障诊断系统对机头、机尾处的故障也能有效诊断。实验表明,基于谱聚类的故障诊断系统能够实现对工业现场设备产生各类型噪音信号的诊断。

3.3 实验结果验证

西山焦煤(集团)有限公司屯兰选煤厂煤质输送带总长 1 395 m,其中矸石皮带总长近 650 m,共有上千个传送托辊。在正常生产时,每天因各种原因都会有托辊产生故障,不同类型的故障需要有不同的应对措施。先前主要通过人工巡检发现故障后从而采取措施,效率低且不能实时诊断处理故障。

选煤厂选煤效率直接影响到其经济效益的高低,智能化托辊故障诊断系统的应用能够实时有效地识别故障,便于实时维护。智能化托辊故障诊断系统界面如图 11 所示,通过对工业现场实时监控,能够显示出设备运行状态以及故障的大概范围。

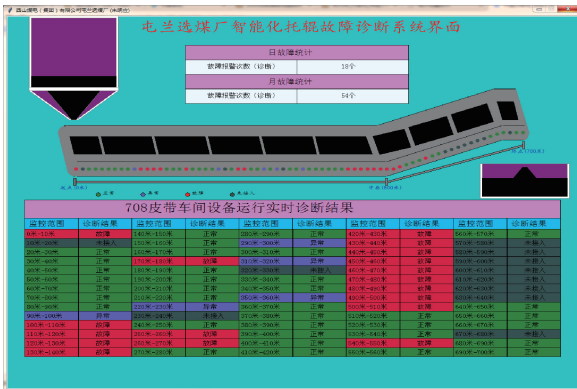


图 11 智能化托辊故障诊断系统界面

智能化托辊故障诊断系统无论在故障诊断识别的精度还是实时故障报警的速度都能够满足生产需求,相较人工巡检有较大提高。经实践应用测试表明,该系统有效地提高了生产智能化,降低工人劳动量。将智能化托辊故障诊断技术应用于选煤过程,能够切实保证设备高效运行,降低设备在运行中的大范围故障发生的隐患,有助于提高选煤工作效率,大幅度减少非计划停机次数,其应用产生了较好的经济效益。

4 结 论

本文利用谱聚类算法对工业现场复杂环境下的多类型时变噪音音频信号处理分析,借鉴以往机械故障诊断中相关特征提取的方法,同时根据实际应用场景,选用谱聚类算

法,并创新性地利用来自同一长段音频样本切割的子样本应属于同一类型作为算法的判别标准。进一步通过调整谱聚类构建子图相似样本的个数,提高判别准确率。

在现场实际应用中,为改善音频实时变化所带来诊断误差,根据实时音频动态改变模型参数,进一步改善系统实时诊断准确率。该算法模型在保证准确率的前提下有较强的泛化能力,有效地解决了托辊的故障诊断问题,极大改善了生产效率。

已有文献关于机械故障诊断问题相较于本研究来说,所需区分的音频样本类型较少,便于获取样本标签信息,而工业生产现场却有大量不同机械碰撞所产生的音频,因而无法获取全部样本标签;设备运行期间音频信号变化相对稳定,即正常信号和故障信号不会随着时间相互演变,而本文所研究问题在生产过程中空载的干扰音频信号却会和载重过程中的故障信号一致,因而需要根据采集到的实时音频信号设定动态参数;以往所用模型无需较强的泛化性能,而该模型需要实现 700 m 范围内不同工位的故障诊断,因而需要较强的泛化性能。

本文模型的特征提取主要根据以往研究经验,能有效地对托辊故障进行实时诊断,但处理过程较为繁琐,如特征提取提取前,需要对音频进行切割、差分等预处理操作,如何简化数据处理以及特征提取过程,来获取更加有效的特征直接对长段音频整体进行诊断,以便提高软件实时诊断准确率以及运行效率,则是该研究进一步的探索方向。

参考文献

- [1] PEARN W L, ASSAD A, GOLDEN B L. Transforming arc routing into node routing problems[J]. Computers & Operations Research, 1987, 14(4): 285-288.
- [2] 陆汝华,段盛,杨胜跃,等.基于 CGHMM 的轴承故障音频信号诊断方法[J].计算机工程与应用,2009,45(11):223-225,234.
- [3] KOTSIANTIS S B, ZAHARAKIS I, PINTELAS P. Supervised machine learning: A review of classification techniques [J]. Emerging Artificial Intelligence Applications in Computer Engineering, 2007, 160: 3-24.
- [4] HASTIE T, TIBSHIRANI R, FRIEDMAN J. Unsupervised learning [M]. Springer, New York, 2009: 485-585.
- [5] LIU Z, HUANG J, WANG Y, et al. Audio feature extraction and analysis for scene classification [C]. IEEE First Workshop, 1997: 343-348.
- [6] YU Y, CONGMING L, TINGYU W, et al. Fault diagnosis and classification for bearing based on EMD-ICA [C]. 2011 International Conference on IEEE, 2011, 5: 2715-2718.
- [7] 李艳雄,王琴,张雪,等.基于凝聚信息瓶颈的音频事件

- 聚类方法[J].电子学报,2017,45(5):1064-1071.
- [8] ZHANG X Y, LIANG Y, ZHOU J. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM[J]. Measurement, 2015, 69: 164-179.
- [9] Guo G D, LI S Z. Content-based audio classification and retrieval by support vector machines[J]. IEEE transactions on Neural Networks, 2003, 14(1): 209-215.
- [10] DHANALAKSHMI P, PALANIVEL S, RAMALINGAM V. Classification of audio signals using SVM and RBFNN[J]. Expert Systems with Applications, 2009, 36(3): 6069-6075.
- [11] DAVY M, GODSILL S. Detection of abrupt spectral changes using support vector machines an application to audio signal segmentation[C]. 2002 IEEE International Conference on IEEE, 2002(2): 1313-1316.
- [12] LEE J M, KIM S J, HWANG Y, et al. Diagnosis of mechanical fault signals using continuous hidden Markov model[J]. Journal of Sound and Vibration, 2004, 276(3/5): 1065-1080.
- [13] TÜSKE Z, SCHLÜTER R, NEY H. Deep hierarchical bottleneck MRSTA features for VCSR[C]. 2013 IEEE International Conference on IEEE, 2013: 6970-6974.
- [14] 李志农,朱明,褚福磊,等.基于经验小波变换的机械故障诊断方法研究[J].仪器仪表学报,2014,35(11): 2423-2432.
- [15] KOTTI M, MOSCHOU V, KOTROPOULOS C. Speaker segmentation and clustering[J]. Signal Processing, 2008, 88(5): 1091-1124.
- [16] 张宇献,彭辉灯,王建辉.基于异构值差度量的 SOM 混合属性数据聚类算法[J].仪器仪表学报,2016, 37(11): 2555-2562.
- [17] 张焱,汤宝平,邓蕾.基于谱聚类初始化非负矩阵分解的机械故障诊断[J].仪器仪表学报,2013, 34(12): 2806-2811.
- [18] VON LUXBURG U. A tutorial on spectral clustering[J]. Statistics and Computing, 2007, 17(4): 395-416.
- [19] 吴凡.状态监测和故障诊断技术的现状与展望[J].国外电子测量技术,2006,25(3): 5-7.
- [20] WANG P, WANG H, WANG W. Finding semantics in time series[C]. Proceedings of the 2011 ACM SIGMOD International Conference on Management of Data, 2011: 385-396.
- [21] OUYANG R, REN L, CHENG W, et al. Similarity search and pattern discovery in hydrological time series data mining[J]. Hydrological Processes, 2010, 24(9): 1198-1210.
- [22] 宗银雪,张靓,李铁军,等.基于 EMD-ICA 音频特征提取的故障诊断系统设计[J].机械设计与制造,2016(9): 98-101.
- [23] WU X, KUMAR V, QUINLAN J R, et al. Top 10 algorithms in data mining[J]. Knowledge and Information Systems, 2008, 14(1): 1-37.

作者简介

宋天祥,硕士研究生,主要研究方向为工业智能化。

E-mail:18817608993@163.com

彭晨,博士、教授,主要研究方向为网络控制系统分析与综合,时滞系统分析与综合、工业故障诊断与监测、数据仓库知识发现 KDD 与 ERP 系统开发,智能电网与电力系统大数据等。

E-mail:c.peng@shu.edu.cn