



(12) 发明专利

(10) 授权公告号 CN 113657221 B

(45) 授权公告日 2024. 08. 23

(21) 申请号 202110889067.5

(22) 申请日 2021.08.04

(65) 同一申请的已公布的文献号

申请公布号 CN 113657221 A

(43) 申请公布日 2021.11.16

(73) 专利权人 浙江浙能台州第二发电有限责任公司

地址 317109 浙江省台州市三门县浦坝港镇能源路1号

(72) 发明人 马春林 屠海彪 李文杰 杨景焜
王灵敏 杨林豪 朱彬源 吴彦锋
严寒夕

(74) 专利代理机构 浙江永鼎律师事务所 33233
专利代理师 陆永强

(51) Int.Cl.

G06F 18/2411 (2023.01)

G06F 18/214 (2023.01)

G06F 18/213 (2023.01)

G06F 18/24 (2023.01)

G10L 25/51 (2013.01)

(56) 对比文件

CN 112233695 A, 2021.01.15

审查员 许莹云

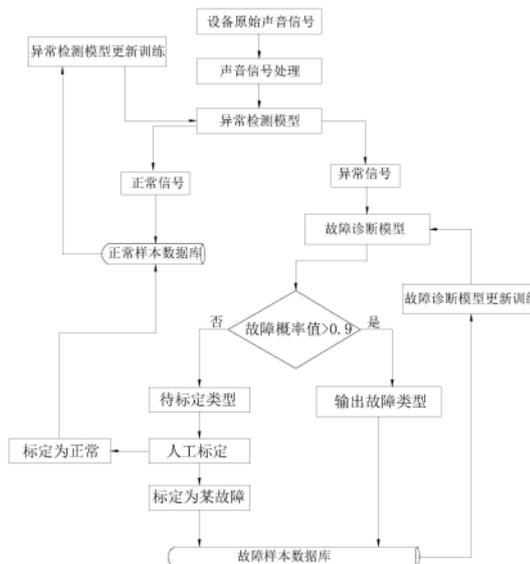
权利要求书2页 说明书8页 附图4页

(54) 发明名称

一种基于智能感知技术的电厂设备状态监测方法

(57) 摘要

本发明提供了一种基于智能感知技术的电厂设备状态监测方法,包括以下步骤:S1.采集设备运行过程中的声音信号;S2.由异常检测模型对声音信号进行异常检测,当检测到异常信号时,将异常信号输入至故障诊断模型;S3.由故障诊断模型对异常信号进行故障诊断。本方案根据故障诊断模型对故障类型的概率值,进行可靠性判断,并对可靠性不高的判断结果输出等待人工标定,在使用过程中不断优化故障诊断模型,随着模型的不断使用,能够不断提高故障类型判断准确率,能够解决因故障类型数据不足而引起实际使用中故障诊断信号漏判的问题。



1. 一种基于智能感知技术的电厂设备状态监测方法,其特征在于,包括以下步骤:

S1. 以第一采集频率采集设备运行过程中的声音信号;

S2. 由异常检测模型对声音信号进行异常检测,当检测到异常信号时,以第二采集频率采集设备运行过程中的声音信号,且同时将异常信号和以第二采集频率采集到的声音信号输入至故障诊断模型;

所述的第二采集频率大于第一采集频率;

异常检测模型同时对以第二采集频率采集设备运行过程中的声音信号进行检测,当持续预设次数/时间的声音信号均被检测为正常声音信号时,恢复为第一采集频率;

S3. 由故障诊断模型对异常信号进行故障诊断,故障诊断模型输出故障类型及相应故障类型的故障概率值判定;

所述的异常检测模型和故障诊断模型均为经过训练的模型,且故障诊断模型采用异常数据进行训练得到;

S4. 判断所述的故障概率值是否高于预设概率值,预设概率值作为能否准确判断的临界点,若故障概率值高于预设概率值,认为对故障类型做出了准确判断,直接输出故障类型,否则执行步骤S5;

S5. 将判定的故障类型和故障概率值输出,等待工作人员给出人为标定结果;

当工作人员给出人为标定结果后,将标定结果作为相应声音信号的给定标签,若标定为正常,则将相应的声音信号放入正常样本数据库,并对异常检测模型进行训练更新,若标定为某故障,则将相应的声音信号放入故障样本数据库,并对故障诊断模型进行训练更新。

2. 根据权利要求1所述的基于智能感知技术的电厂设备状态监测方法,其特征在于,所述的异常检测模型为单类支持向量机,且所述的异常检测模型预先通过以下方式训练获得:

A1. 获取第一样本数据;

A2. 对第一样本数据中的声音信号进行预处理;

A3. 对预处理后的声音信号进行特征提取组成特征向量;

A4. 对所述的特征向量进行降维处理;

A5. 利用经过降维处理的特征训练单类支持向量机,建立异常检测模型;

步骤S2中,先对采集的声音信号进行包括预处理、特征提取和降维处理的数据处理后输入异常检测模型以由异常检测模型对声音信号进行异常检测。

3. 根据权利要求2所述的基于智能感知技术的电厂设备状态监测方法,其特征在于,所述的第一样本数据中的声音信号均为正常信号;

或者,所述的第一样本数据中的声音信号包括打了正常标签的正常信号和打了异常标签的异常信号。

4. 根据权利要求2所述的基于智能感知技术的电厂设备状态监测方法,其特征在于,步骤A2具体为:

A21. 对声音信号进行滤波处理,使用高通滤波器滤除50Hz以下的低频干扰信号;

A22. 将声音分段,对每一段声音使用滑动窗分帧处理。

5. 根据权利要求4所述的基于智能感知技术的电厂设备状态监测方法,其特征在于,步骤A3中,所提取的特征包括时域上的裕度因子、脉冲因子、偏斜因子和频谱上的重心频率、

均方频率、频率特征。

一种基于智能感知技术的电厂设备状态监测方法

技术领域

[0001] 本发明属于电厂设备状态监测技术领域,尤其是涉及一种基于智能感知技术的电厂设备状态监测方法。

背景技术

[0002] 当前,电厂的设备常采用检测方法,通常是对设备进行周期性的检查和维护,主要依靠人工经验和基于历史数据。由于大多数设备、备件的故障间隔离散性较大,这种方法存在着一定的弊端:一是维护效果受限、成本较高。固定周期的巡检若周期过于频繁则不仅产生巨大的人力成本,还可能会产生一些不必要的,甚至有损害性的维护活动。二是若周期不够频繁,则又会带来较大的设备故障风险,带来更大的损失。因此,通过先进的技术手段,对设备运行的实时参数进行监测和分析,来判断设备是否存在异常或故障、故障的部位和原因、故障的劣化趋势,进而确定合理检修时机,把事故消灭在萌芽状态,有效地降低维修成本,降低事故停机率,是非常有必要的。

[0003] 电厂生产环境中有很大的噪音,不同设备的声音混杂在相对集中的空间中,由于过去针对声音信号没有很好的技术手段去处理,所以仅仅只能依靠具有丰富专业经验的巡检人员才能听出设备的异常声音,而随着电厂设备向着高、精、尖方向发展,仅依靠巡检人员,难以对设备的运行状态做到有效和准确的判断。在实际系统中,设备在不同工作条件下的运行状态不同,当工作条件发生改变时如故障发生,设备运行状态将发生改变。虽然状态改变过程中设备的声音信号产生的机理比较模糊,但这种声音信号往往具有非平稳特性,故可以采用统计模型理论来分析处理。设备状态在改变过程中往往会引起声音信号结构的变化、出现不同的声音波形图,如图1所示,可以通过设备状态声音信号特征的变化判断出设备的运行状态,甚至用以判别设备故障类型和发生部位。

[0004] 近年来,随着预测控制、核偏最小二乘、神经网络以及支持向量机等技术和机器学习算法的发展并在工业上获得成功应用,可以充分利用电厂充足的历史运行数据建立设备故障诊断的模型,实现设备状态的在线分析和智能预警,然而,随着电厂设备高速发展,新的故障类型逐渐增多。在其实际生产中,将故障信号漏判或者误判成正常信号都有可能带来较大的损失。基于历史数据训练的故障诊断模型一定会将这些新型故障判别到某一类已有的类别中。而且设备运行中正常运行数据远远高于故障类型数据,模型对这些非常少量的故障数据很容易造成误判或者漏判。

[0005] 为实现对电厂设备故障类型的准确判断与预警,必须寻求一种新的故障诊断方法,来解决因故障类型数据不足而引起的实际使用中故障诊断模型将故障信号漏判和误判的问题。

发明内容

[0006] 本发明的目的是针对上述问题,提供一种基于智能感知技术的电厂设备状态监测方法。

[0007] 为达到上述目的,本发明采用了下列技术方案:

[0008] 一种基于智能感知技术的电厂设备状态监测方法,包括以下 步骤:

[0009] S1.采集设备运行过程中的声音信号;

[0010] S2.由异常检测模型对声音信号进行异常检测,当检测到异常 信号时,将异常信号输入至故障诊断模型;

[0011] S3.由故障诊断模型对异常信号进行故障诊断。

[0012] 在上述的基于智能感知技术的电厂设备状态监测方法中,所 述的异常检测模型为单类支持向量机,且所述的异常检测模型预 先通过以下方式训练获得:

[0013] A1.获取第一样本数据;

[0014] A2.对第一样本数据中的声音信号进行预处理;

[0015] A3.对预处理后的声音信号进行特征提取组成特征向量;

[0016] A4.对所述的特征向量进行降维处理;

[0017] A5.利用经过降维处理的特征训练单类支持向量机,建立异常 检测模型;

[0018] 步骤S2中,先对采集的声音信号进行包括预处理、特征提取 和降维处理的数据处理后输入异常检测模型以由异常检测模型对 声音信号进行异常检测。

[0019] 在上述的基于智能感知技术的电厂设备状态监测方法中,所 述的第一样本数据中的声音信号均为正常信号;

[0020] 或者,所述的第一样本数据中的声音信号包括打了正常标签 的正常信号和打了异常标签的异常信号。

[0021] 在上述的基于智能感知技术的电厂设备状态监测方法中,步 骤A2具体为:

[0022] A21.对声音信号进行滤波处理,使用高通滤波器滤除50Hz 以下的低频干扰信号;

[0023] A22.将声音分段,对每一段声音使用滑动窗分帧处理。

[0024] 在上述的基于智能感知技术的电厂设备状态监测方法中,步 骤A3中,所提取的特征包括时域上的裕度因子、脉冲因子、偏斜 因子和频谱上的重心频率、均方频率、频率特征。

[0025] 在上述的基于智能感知技术的电厂设备状态监测方法中,步 骤A5中,使用蚁群算法进行参数寻优,以得到单类支持向量机的 最优核函数参数和权衡参数,将最优核函数参数和权衡参数代入 支持向量机后得到训练后的异常检测模型,目标函数的初始问题 为:

$$\begin{aligned} & \min_{\omega, \xi, \rho} \frac{1}{2} \|\omega\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - \rho \\ [0026] \quad & s.t. \begin{cases} \omega^T y(x_i) \geq \rho - \xi_i \\ \xi_i \geq 0, i = 1, 2, \dots, l \end{cases} \end{aligned} \quad (1)$$

$$[0027] \quad \text{采用高斯核函数: } H(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (2)$$

$$[0028] \quad \text{满足条件: } H(x_i, x_j) = y(x_i)^T y(x_j) \quad (3)$$

[0029] (1)式的拉格朗日对偶问题为:

$$\begin{aligned}
 & \min \frac{1}{2} \sum_{i=1}^l \lambda_i \lambda_j H(x_i, x_j) \\
 [0030] \quad & \text{s.t.} \begin{cases} \sum_{i=1}^l \lambda_i = 1 \\ 0 \leq \lambda_i \leq \frac{1}{vn}, i = 1, 2, \dots, l \end{cases} \quad (4)
 \end{aligned}$$

[0031] 解出各 λ_i 后,得到判别函数为:

$$[0032] \quad f(x) = \text{sign}(\sum_{i=1}^l \lambda_i H(x_i, x) - \rho) \quad (5)$$

$$[0033] \quad (5) \text{ 式中 } \rho = \sum_{i=1}^l \lambda_i H(x_i, x_j) \quad (6)$$

[0034] 上述各式中, l 为训练样本的数量;

[0035] σ 为所要求的最优核函数参数;

[0036] $v \in (0, 1]$ 为权衡参数,是通过上述蚁群算法预先定义好的百分比参数估计,表示支持向量和错分向量之间的折中;

[0037] ρ 为特征空间中所需超平面的补偿;

[0038] ω 为特征空间中所需超平面的法向量;

[0039] ξ_i 为松弛变量;

[0040] λ_i, λ_j 为拉格朗日乘子, x_i, x_j 为原空间中的样本。

[0041] 在上述的基于智能感知技术的电厂设备状态监测方法中,步骤S3中,所述的故障诊断模型用于输出故障类型及相应故障类型的故障概率值判定;

[0042] 且步骤S3之后还包括:

[0043] S4. 判断所述的故障概率值是否高于预设概率值,若是,则直接输出故障类型,否则执行步骤S5;

[0044] S5. 将判定的故障类型和故障概率值输出,等待工作人员给出人为标定结果。

[0045] 在上述的基于智能感知技术的电厂设备状态监测方法中,步骤S5中,当工作人员给出人为标定结果后,将标定结果作为相应声音信号的给定标签,并将具有给定标签的声音信号输入至异常检测模型和/或故障诊断模型进行训练更新。

[0046] 在上述的基于智能感知技术的电厂设备状态监测方法中,步骤S1中,以第一采集频率采集设备运行过程中的声音信号;

[0047] 步骤S2中,当检测到异常信号时,以第二采集频率采集设备运行过程中的声音信号,且同时将异常信号和以第二采集频率采集到的声音信号输入至故障诊断模型;

[0048] 所述的第二采集频率大于第一采集频率。

[0049] 在上述的基于智能感知技术的电厂设备状态监测方法中,步骤S2中,异常检测模型同时对以第二采集频率采集设备运行过程中的声音信号进行检测,当持续预设次数/时间的声音信号均被检测为正常声音信号时,恢复为第一采集频率。

[0050] 本发明的优点在于:

[0051] 1、能够解决因故障类型数据不足而引起实际使用中故障诊断 信号漏判的问题；
 [0052] 2、根据故障诊断模型对故障类型的概率值,进行可靠性判断,并对可靠性不高的判断结果输出等待人工标定,在使用过程中不 断优化故障诊断模型,随着模型的不 断使用,能够不断提高故障 类型判断准确率。

附图说明

[0053] 图1是设备在不同的运行状态下的声音波形图；
 [0054] 图2是本发明中异常检测模型的训练流程图；
 [0055] 图3是本发明中故障诊断模型的训练流程图；
 [0056] 图4是本发明基于智能感知技术的电厂设备状态监测方法的 判断方法流程图；
 [0057] 图5是ROC曲线评价异常检测模型性能—AUC(Area Under Curve)图。

具体实施方式

[0058] 下面结合附图和具体实施方式对本发明做进一步详细的说 明。

[0059] 如图2所示,本实施例公开了一种基于智能感知技术的电厂 设备状态监测方法,首先准备经过训练的异常检测模型和故障故 障诊断模型。

[0060] 这里的异常检测模型采用单类支持向量机,且异常检测模型 主要通过以下训练获得:

[0061] A1.获取第一样本数据;该第一样本数据中的声音信号可以均 为正常信号;也可以包括打了正常标签的正常信号和打了异常标 签的异常信号。

[0062] A2.对第一样本数据中的声音信号进行预处理,首先对声音信 号进行滤波处理,使用高通滤波器滤除50Hz以下的低频干 扰信 号;再将声音分为6s每段,对每一段声音使用滑动窗分帧处理,窗长0.25s,窗移50%,即每次移动窗长的一半。

[0063] A3.对预处理后的声音信号进行特征提取,组成特征向量:提 取所有帧信号在时域上的统计特征以及在频谱分布上的特征,如 时域上的裕度因子、脉冲因子、偏斜因子和 频谱上的重心频率、均方频率、频率特征,设fs为采样频率,每秒的连续声音信号s(t) 经过采样离散化为s(n),设对每6秒信号进行分帧处理的帧长为N, 帧移为N/2,总帧数为N_F。则第i帧信号s_i(n)在时域的统计特征, 裕度因子,提取公式为:

$$[0064] \quad C_{mf} = \frac{\max(|s_i(n)|)}{\left(\frac{1}{N} \sum_{i=1}^N |s_i(n)|^2\right)^{\frac{1}{2}}} \quad (1)$$

[0065] 脉冲因子,提取公式为:

$$[0066] \quad C_{if} = \frac{\max(|s_i(n)|)}{\left(\frac{1}{N} \sum_{i=1}^N s_i(n)\right)} \quad (2)$$

[0067] 偏斜因子,提取公式为:

$$[0068] \quad X_{sf} = \frac{\sum_{i=1}^N (s_i(n) - \frac{\sum_{i=1}^N s_i(n)}{N})^3}{N(\sqrt{\sum_{i=1}^N (s_i(n) - \frac{\sum_{i=1}^N s_i(n)}{N})^2})^3} \quad (3)$$

[0069] $s(n)$ ($n=1, 2, \dots, N$) 为时域信号, N 为信号样本长度。

[0070] 信号功率谱反映的是信号能量随机分布情况, 即从信号中的 频率成分和频率成分的能量大小情况分析信号的特征。对信号 $s(n)$ 做傅里叶变换, 得到其在频谱上的分布信息, 快速傅里叶变换 的公式为:

$$[0071] \quad S_i(k) = \sum_{n=0}^{N-1} s_i(n) e^{-j\frac{2n\pi}{N}k}, \quad k=0, \dots, N-1 \quad (4)$$

[0072] 其中, $s_i(k)$ 是第 i 帧信号 $s_i(n)$ 的STFT (短时傅里叶变换)。

[0073] 则第 i 帧信号 $s_i(k)$ 在频域的特征,

[0074] 重心频率, 提取公式为:

$$[0075] \quad FC = \frac{\sum_{k=1}^K f_k s_i(k)}{\sum_{k=1}^K y(k)} \quad (5)$$

[0076] 均方频率, 提取公式为:

$$[0077] \quad MSF = \frac{\sum_{k=1}^K (y(k) - \frac{\sum_{k=1}^K y(k)}{K})^2}{K-1} \quad (6)$$

[0078] 频率特征, 提取公式为:

$$[0079] \quad F2 = \frac{\sqrt{\sum_{k=1}^K (f_k^2 y(k))}}{\sum_{k=1}^K y(k)} \quad (7)$$

[0080] $y(k)$ ($k=1, 2, \dots, K$) 为信号 $s(n)$ 的谱值, K 为谱线数, f_k 是频率值。将信号在时域和频域的以上特征参数组成一个6维向量, 作为一段声音信号的特征向量。

[0081] A4. 对所述的特征向量进行降维处理: 找出主要特征, 用主要特征代替原始数据;

[0082] A5. 利用经过降维处理的特征训练单类支持向量机, 建立异常检测模型, 具体为:

[0083] 对降维后的特征参数进行归一化处理; 使用蚁群算法进行参数寻优, 得到单类支持向量机的最优核函数参数和权衡参数, 构造并解决最优问题; 目标函数的初始问题为:

$$\begin{aligned}
 & \min_{\omega, \xi, \rho} \frac{1}{2} \|\omega\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - \rho \\
 & s.t. \begin{cases} \omega^T y(x_i) \geq \rho - \xi_i \\ \xi_i \geq 0, i = 1, 2, \dots, l \end{cases}
 \end{aligned} \quad (8)$$

[0085] 采用高斯核函数: $H(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$ (9)

[0086] 满足条件: $H(x_i, x_j) = y(x_i)^T y(x_j)$ (10)

[0087] (8) 式的拉格朗日对偶问题为:

$$\begin{aligned}
 & \min \frac{1}{2} \sum_{i=1}^l \lambda_i \lambda_j H(x_i, x_j) \\
 & s.t. \begin{cases} \sum_{i=1}^l \lambda_i = 1 \\ 0 \leq \lambda_i \leq \frac{1}{\nu n}, i = 1, 2, \dots, l \end{cases}
 \end{aligned} \quad (11)$$

[0089] 解出各 λ_i 后, 得到判别函数为:

$$f(x) = \text{sign}\left(\sum_{i=1}^l \lambda_i H(x_i, x) - \rho\right) \quad (12)$$

$$(12) \text{ 式中 } \rho = \sum_{i=1}^l \lambda_i H(x_i, x_j) \quad (13)$$

[0092] 上述各式中, l 为训练样本的数量;

[0093] σ 为所要求的最优核函数参数;

[0094] $\nu \in (0, 1]$ 为权衡参数, 为预先定义好的百分比参数估计, 表示支持向量和错分向量之间的折中;

[0095] ρ 为特征空间中所需超平面的补偿;

[0096] ω 为特征空间中所需超平面的法向量;

[0097] ξ_i 为松弛变量;

[0098] λ_i, λ_j 为拉格朗日乘子, x_i, x_j 为原空间中的样本。

[0099] 将由蚁群算法寻优得到的单类支持向量机模型参数 (ν, σ) 的最佳值代入支持向量机后得到训练后的异常检测模型。

[0100] 故障诊断模型采用由输入层、特征提取层和分类层构成的一维卷积神经网络。如图3所示, 将标记故障类型的异常信号输入到故障诊断模型中进行训练即可得到训练后的故障诊断模型。异常信号可以由工作人员提前准备, 也可以由异常检测模型对第二样本数据进行检测, 即将第二样本数据进行处理后输入至上述判别函数(12), 得到异常信号的训练样本集 D , 然后再由工作人员对训练样本集中的数据按不同的故障类型进行分类, 分别标记为 D_1, D_2, \dots, D_k , 并做好分类标记。

[0101] 第一样本数据和第二样本数据可以使用不同样本数据, 也可以使用同一样本数

据。

[0102] 在投入使用时,如图4所示,将采集到的设备原始信号输入至异常检测模型进行异常判断,然后将异常信号输入至故障诊断模型,由故障诊断模型进行故障分类。具体方法如下:

[0103] S1.以第一采集频率采集设备运行过程中的声音信号,第一采集频率可以取10分钟一次,每次采集6s时间;可以使用磁吸在待测设备上的声音传感器采集设备运行过程中的声音信号,磁吸安装方式能够直接获取设备内部的声音,降低了环境噪声对信号的影响,优选利用仿人耳听力的智能声音传感器,并且通过应用物联网5G技术,来解决声音信号收集传输迟延的问题。

[0104] S2.对采集的声音信号进行包括预处理、特征提取和降维处理的处理后输入异常检测模型,以由异常检测模型对声音信号进行异常检测,当检测到异常信号时,将异常信号输入至故障诊断模型;

[0105] S3.由故障诊断模型对异常信号进行故障诊断。

[0106] 由于异常检测模型不可能百分之百把正常信号和异常信号区分开,有可能把设备运行在极端工况的一些正常信号误判成异常信号(故障诊断模型不会将异常信号判断为正常信号,但是有可能将正常信号判断为异常信号),因此检测后的数据可能包含以知故障类型和异常类型(未知故障类型或正常),所以本实施例在故障识别模型后添加判断条件,用以将异常类型区分出来。

[0107] 具体为,步骤S3中,故障诊断模型不仅输出故障类型,还输出相应故障类型的故障概率值;

[0108] 且步骤S3之后还包括:

[0109] S4.判断故障概率值是否高于预设概率值,如0.9,预设概率值作为能否准确判断的临界点,若故障概率值是否高于预设概率值,则认为对故障类型做出了准确判断,直接输出故障类型,否则执行步骤S5;

[0110] S5.认为对故障类型无法做出准确判断,将判定的故障类型和故障概率值输出,等待工作人员给出人为标定结果。

[0111] 当工作人员给出人为标定结果后,将标定结果作为相应声音信号的给定标签,并将具有给定标签的声音信号输入至异常检测模型和/或故障诊断模型进行训练更新。若标定为正常,则将相关声音信号放入正常样本数据库,并对异常检测模型进行训练更新,若标定为异常,则将声音信号放入故障样本数据库,并对故障诊断模型进行训练更新。

[0112] 优选地,当检测到异常信号时,以第二采集频率采集设备运行过程中的声音信号,且同时将异常信号和以第二采集频率采集到的声音信号输入至故障诊断模型;第二采集频率可以为1分钟一次,一次6s时间。正常情况下10-30分钟采集一次,在初步判断为异常的时候提高采集频率,既能够满足节约能耗,避免频繁采集的需求,又能够满足对异常时候数据的持续采集,具有类似巡检效果。

[0113] 进一步地,异常检测模型同时对以第二采集频率采集设备运行过程中的声音信号进行检测,当持续预设次数/时间的声音信号均被检测为正常声音信号时,恢复为第一采集频率。即当声音信号异常的时候,持续采集声音信号,利于模型对故障状态进行诊断,当声音信号正常的时候,没必要频繁采集,又恢复为长间隔时间采集。

[0114] 下面采用ROC-AUC模型评价指标对上述OCSVM异常检测模型进行评价。首先手动将测试数据打标签,人工识别正常声音和异常声音数据。接下来将标签的测试数据输入ROC-AUC评价程序中,获取ROC的结果图如图5所示。在ROC的结果图中,曲线越接近坐标系的右上角,证明模型的准确度越高,效果也好。考虑到ROC曲线本身并不能直观的说明一个分类器性能的好坏,而AUC表示ROC曲线下的面积,主要用于衡量模型的泛化性能,即分类效果的好坏,其值作为一个 $[0, 1]$ 的数量值,其值越接近1,被评价的模型,具有可比较性,可以进行定量的比较。上述模型的AUC值为0.891,证明此模型在特定情况的声音异常检测中优秀的完成了任务。

[0115] 本方案提出先异常检测后故障诊断,对故障诊断模型只使用异常数据进行训练,避免不平衡样本对分类模型识别准确率的影响;由于异常检测模型能够将一切异常信号检测出来,所以同时能够很好地解决因故障类型数据不足而引起实际使用中故障诊断模型将故障漏判的问题;而且根据诊断输出的概率值判断是否可靠,对于不可靠结果等待人工标定并进一步更新训练模型,随着模型的不断使用,能够不断提高模型诊断准确率。

[0116] 本文中所描述的具体实施例仅仅是对本发明精神作举例说明。本发明所属技术领域的技术人员可以对所描述的具体实施例做各种各样的修改或补充或采用类似的方式替代,但并不会偏离本发明的精神或者超越所附权利要求书所定义的范围。

[0117] 尽管本文较多地使用了声音信号、异常检测额模型、故障诊断模型、单类支持向量机、正常信号、异常信号等术语,但并不排除使用其它术语的可能性。使用这些术语仅仅是为了更方便地描述和解释本发明的本质;把它们解释成任何一种附加的限制都是与本发明精神相违背的。

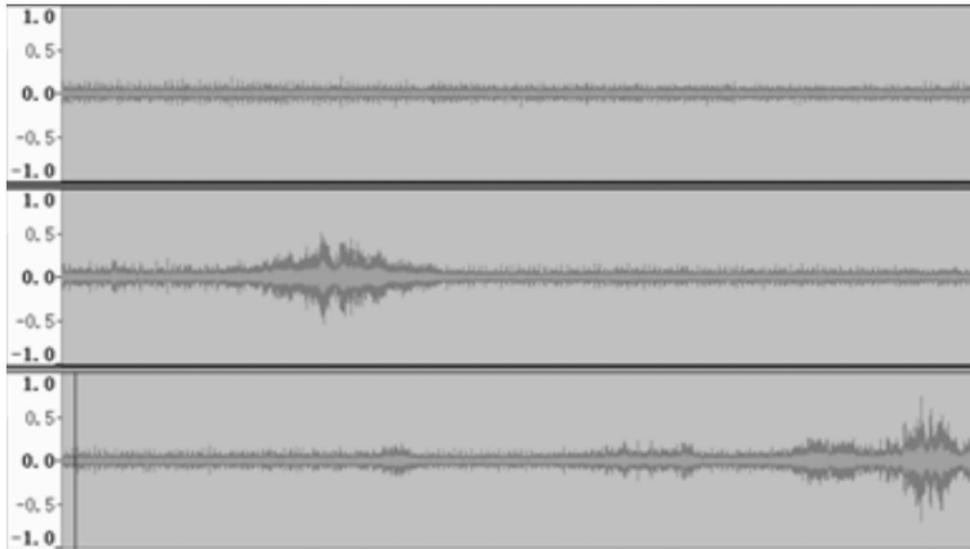


图1

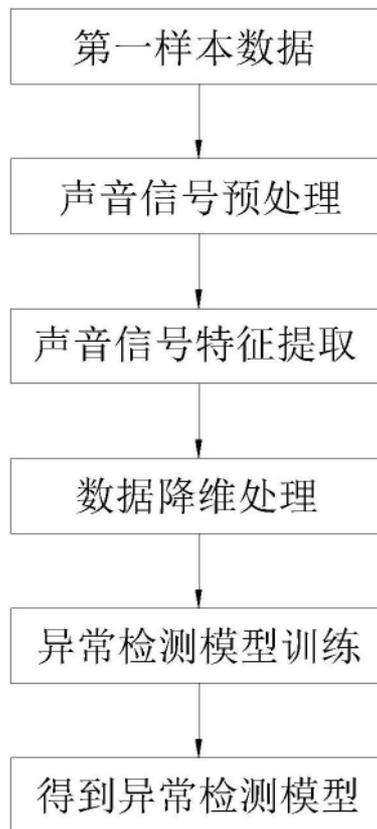


图2

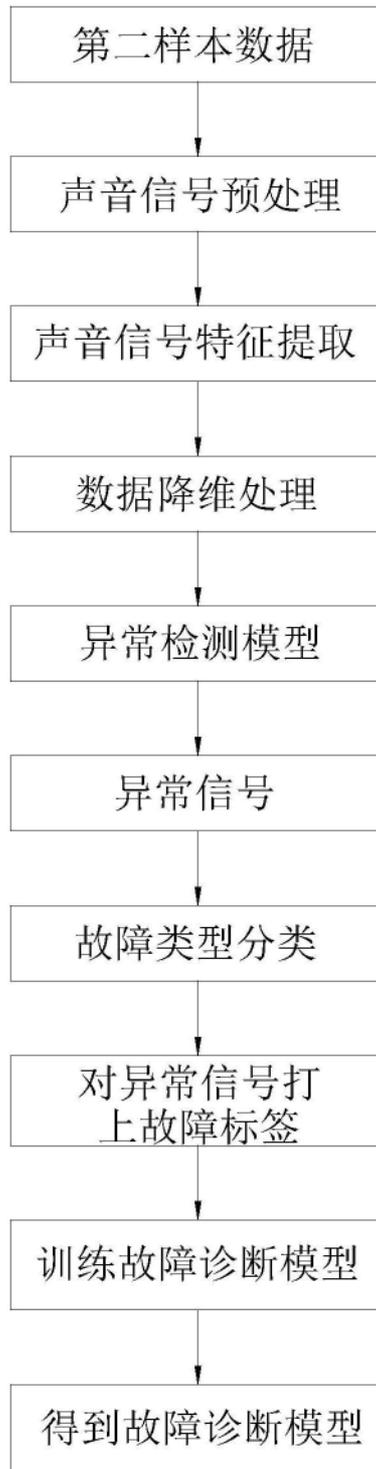


图3

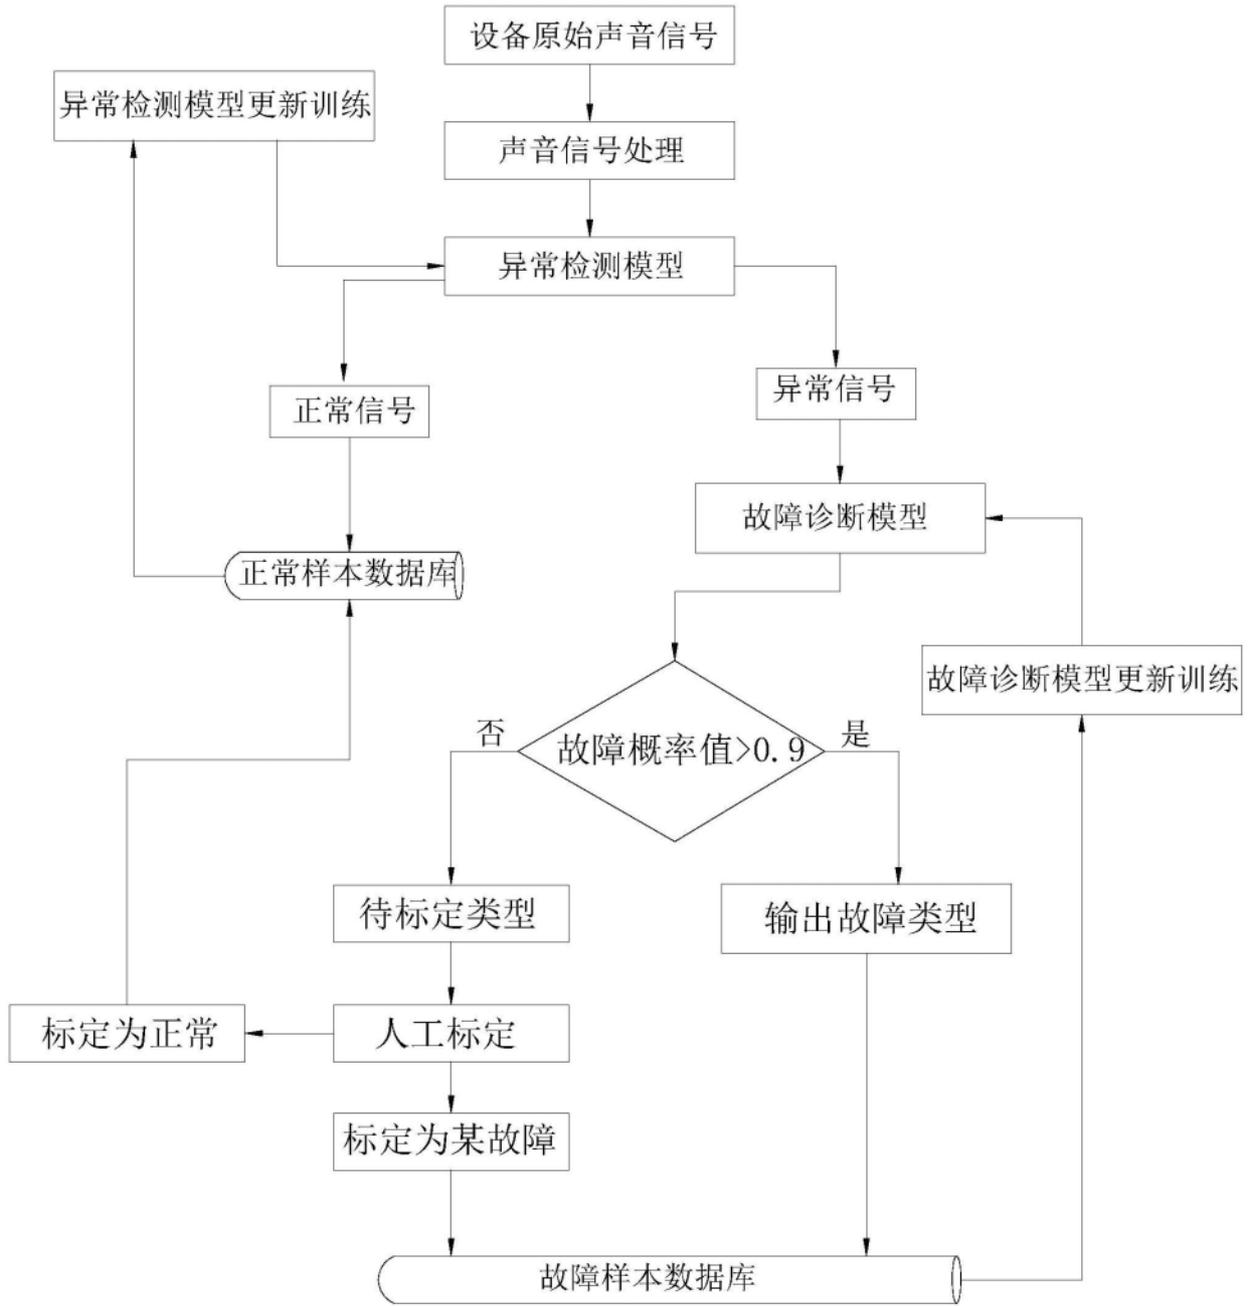


图4

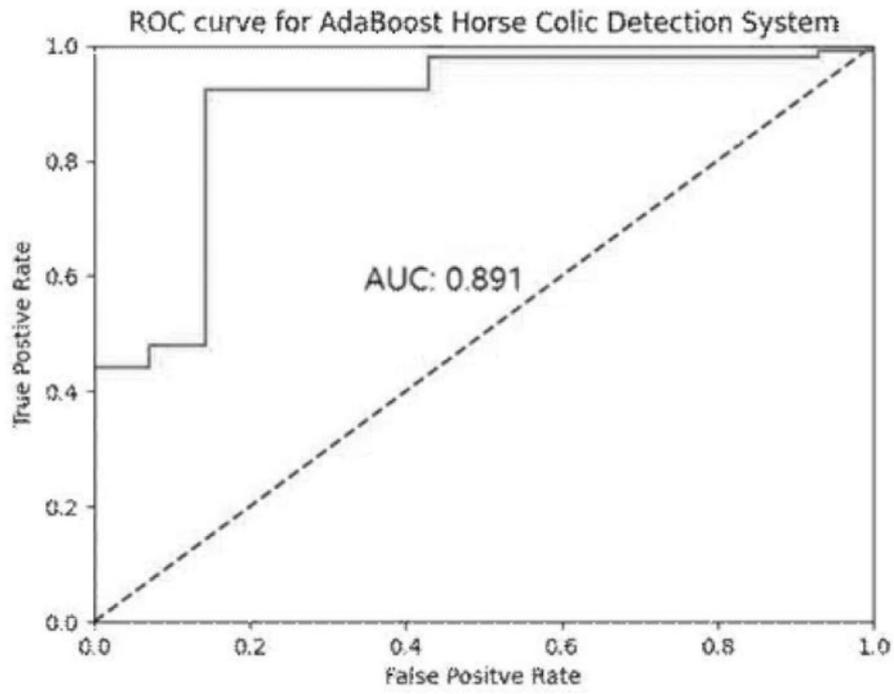


图5