

动设备故障检测方法及系统

技术领域

本发明涉及故障检测技术领域，具体地涉及一种动设备故障检测方法及一种动设备故障检测系统。

背景技术

动设备在企业生产中应用十分广泛，其是企业生产的动力核心设备，例如电机设备和齿轮设备等。这些设备的稳定性直接关乎了生产进程的稳定性，所以在生产过程中，进行动设备运行状态检测是必不可少的。在现有的动设备故障检测技术中，主要依靠人工巡检的方式进行动设备振动状态信号采集，然后基于采集的振动信号进行动设备故障检测。这种方式下，往往都是通过预训练一种模型，然后将采集的特征信号作为模型入参进行训练，基于训练结果获得故障诊断结果。但是，众所周知，动设备随着工作内容不同，工作状态、工作结构、工作流质等都存在极大差异，不同的故障类型下，对应的故障特征信号的差异十分明显，若基于固定的单一模型进行差异很大的多种信号进行特征提取，以基于提取的特征进行故障诊断，其诊断结果的精准度难以保证。针对现有动设备故障检测方案准确度低的问题，需要创造一种新的动设备故障检测方法。

发明内容

本发明实施方式的目的是提供一种动设备故障检测方法及系统，以至少解决现有动设备故障检测方案准确度低的问题。

为了实现上述目的，本发明第一方面提供一种动设备故障检测方法，所述方法包括：采集目标设备的检测信号；基于自相关特性对所述检测信号进行故障类型分类；基于分类结果选择对应的故障诊断模型；基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。

可选的，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。

可选的，所述动设备为工作时存在运动部件，且运动部件在工作时会产出振动信号和/或声学信号的设备。

可选的，所述故障类型包括：机械故障和/或流体力学故障。

可选的，所述方法还包括：识别目标设备的设备类型；基于所述设备类型确定目标设备的检测信号特征；基于所述检测信号特征确定滤波规则，并基于所述滤波规则进行目标设备的检测信号采集。

可选的，所述设备类型包括：机械动设备，包括往复型动设备和离心型动设备；空气动力学动设备，包括气体介质设备和液体介质设备。

可选的，所述基于自相关特性对所述检测信号进行故障类型分类，包括：基于检测信号自相关获得检测信号的不规则程度，并基于所述不规则程度判定产生当前检测信号的设备故障类型；基于确定的设备故障类型选定对应故障类型诊断模型。

可选的，所述基于检测信号自相关获得检测信号的不规则程度，包括：截取一段时间的检测信号，并对该段检测信号按照预设时移进行时移处理，获得对应的时移信号；基于该段检测信号和对应的时移信号构建自相关函数；计算所述

自相关函数的熵；以该段检测信号的自相关函数的熵表征该段检测信号的不规则程度；其中，所述自相关函数的熵越小，不规则程度越大。

可选的，所述自相关函数的表达式为：

$$R_x(\tau) = \int_{-\infty}^{+\infty} x(t)x(t-\tau)dt$$

其中， t 为信号采集时刻； τ 为时移； $x(t)$ 为当前时间段内 t 时刻的检测信号； $x(t-\tau)$ 为当前时间段内 t 时刻检测信号的时移信号；所述自相关函数的熵的计算式为：

$$H = -c \sum_{x=1}^n R_x(\tau) * \log(R_x(\tau))$$

其中， c 为预设常数； H 为相关函数的熵。

可选的，所述基于所述不规则程度判定产生各检测信号的设备故障类型，包括：对比一段检测信号的自相关函数的熵与预设熵阈值；若自相关函数的熵不大于预设熵阈值，则产生该段检测信号的设备故障类型为机械故障类型；若自相关函数的熵大于预设熵阈值，则产生该段检测信号的设备故障类型为流体力学异常类型。

可选的，当前故障类型诊断模型为机械故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测信号进行奇异谱和高阶谱融合分析，获得分析后数据，作为特征信息；当前故障类型诊断模型为流体力学故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测信号进行短时傅里叶变换处理，获得对应的频谱图像，作为特征信息。

可选的，所述基于所述特征信息进行选择的故障诊断模型训练，基于训练结果进行故障设备识别，包括：将所述特征信息和运行工艺参数作为入参，基于所述机械故障诊断模型进行训练，将获得的训练结果作为机械故障类型分析结果；或将所述特征信息和运行工艺参数作为入参，执行所述流体力学故障诊断模型训练，将获得的训练结果作为流体力学异常类型分析结果；其中，在流体力学异常识别模型训练过程中，基于图像数据增强方法对训练过程进行干扰。

可选的，所述方法还包括：在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；基于各频段的声场云图偏离度获得总偏离度矩阵；将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

本发明第二方面提供一种动设备故障检测装置，所述装置包括：信号采集模块，用于采集目标设备的检测信号；信号分类模块，用于基于自相关特性对所述检测信号进行故障类型分类；模型选择模块，用于基于分类结果选择对应的故障诊断模型；故障诊断模块，用于基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。

可选的，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。

可选的，所述动设备为工作时存在运动部件，且运动部件在工作时会产出振动信号和/或声学信号的设备。

可选的，所述信号分类模块还用于：识别目标设备的设备类型；基于所述设备类型确定目标设备的检测信号特征；基于所述检测信号特征确定滤波规则，并基于所述滤波规则进行目标设备的检测信号采集。

可选的，所述装置还包括验证模块，用于：在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；基于各频段的声场云图偏离度获得总偏离度矩阵；将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

本发明第三方面提供一种动设备故障检测系统，所述系统包括上述的动设备故障检测装置。

本发明第四方面提供一种计算机可读储存介质，该计算机可读存储介质上储存有指令，其在计算机上运行时使得计算机执行上述的动设备故障检测方法。

通过上述技术方案，本发明方案充分考虑不同故障类型的信号特征差异，基于差异最易区分的自相关特性进行显著差异的故障类型区分，以实现基于信号特征进行故障类型区分的技术方案，避免了现有基于故障类型进行故障类型区分方案存在的无法应对复合型设备故障类型区分的问题。基于故障类型区分结果，进行适应性的诊断模型选择，保证选择的诊断模型是适应当前信号特征规律的故障检测模型，从而实现差异化的动设备故障诊断方案，提高故障诊断结果的精准性。

本发明实施方式的其它特征和优点将在随后的具体实施方式部分予以详细说明。

附图说明

附图是用来提供对本发明实施例的进一步理解，并且构成说明书的一部分，与下面的具体实施方式一起用于解释本发明实施例，但并不构成对本发明实施例的限制。在附图中：

图 1 是本发明一种实施方式提供的动设备故障检测方法的步骤流程图；

图 2 是本发明一种实施方式提供的动设备故障检测系统的系统结构图。

具体实施方式

以下结合附图对本发明的具体实施方式进行详细说明。应当理解的是，此处所描述的具体实施方式仅用于说明和解释本发明，并不用于限制本发明。

动设备在企业生产中应用十分广泛，其是企业生产的动力核心设备，例如电机设备和齿轮设备等。这些设备的稳定性直接关乎了生产进程的稳定性，所以在生产过程中，进行动设备运行状态检测是必不可少的。在现有的动设备故障检测技术中，主要依靠人工巡检的方式进行动设备振动状态信号采集，然后基于采集的振动信号进行动设备故障检测。这种方式下，往往都是通过预训练一种模型，然后将采集的特征信号作为模型入参进行训练，基于训练结果获得故障诊断结果。但是，众所周知，动设备随着工作内容不同，工作状态、工作结构、工作流质等都存在极大差异，不同的故障类型下，对应的故障特征信号的差异十分明显，若基于固定的单一模型进行差异很大的多种信号进行特征提取，以基于提取的特征

进行故障诊断，其诊断结果的精准度难以保证。

针对现有动设备故障检测方案准确度低的问题，本发明方案提出一种新的动设备故障检测方法，本发明方案充分考虑不同故障类型的信号特征差异，基于差异最易区分的自相关特性进行显著差异的故障类型区分，以实现基于信号特征进行故障类型区分的技术方案，避免了现有基于故障类型进行故障类型区分方案存在的无法应对复合型设备故障类型区分的问题。基于故障类型区分结果，进行适应性的诊断模型选择，保证选择的诊断模型是适应当前信号特征规律的故障检测模型，从而实现差异化的动设备故障诊断方案，提高故障诊断结果的精准性。

图 1 是本发明一种实施方式提供的动设备故障检测方法的方法流程图。如图 1 所示，本发明实施方式提供一种动设备故障检测方法，所述方法包括：

步骤 S10：采集目标设备的检测信号。

具体的，本发明方案想要实现基于振动信号或者声学信号进行故障检测，因为声学信号和振动信号均是波形信号，二者在动设备正常工作状态下和异常工作状态下均会产生差异，所以本发明方面能够适用声学信号故障检测，同样也能适用振动信号故障检测。

优选的，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。

在本发明实施例中，除了采集需要的特诊信号以外，本发明方案还将采集设备的运行工艺参数。例如，某动设备还存在液体储罐，液体储罐内的液体存量，将会造成设备的信号产出差异，在进行故障诊断是，我们必须避免将这种因为设备工艺状态差异导致的信号差异误识别为故障信号特征差异。基于此，本发明方案进行模型构建和后续诊断训练时，都必须将设备的工艺参数作为一个参考量，从而保证识别结果的精准性。

需要明确的是，本发明方案理论上适用于任何方式的信号采集方案，无论是现有的人工巡检信号采集方案，还是固定或移动式传感器的信号采集方案，只要能够准确采集目标设备的信号特征，理论上都应属于本发明方案的保护范围。

步骤 S20：基于自相关特性对所述检测信号进行故障类型分类。

优选的，所述动设备为工作时存在运动部件，且运动部件在工作时会产出振动信号和/或声学信号的设备。

具体的，动设备，指在石油化工生产装置中主要作用部件为运动的工艺设备。一般可分为流体输送机械类、非均相分离机械类、搅拌与混合机械类、冷冻机械类、结晶与干燥设备类等。具体包括离心式压缩机、回转式压缩机、活塞式压缩机、烟气轮机、汽轮机、风机、离心泵、往复泵、齿轮泵、旋涡泵、螺杆泵、过滤机、离心机、破碎机、旋转窑、搅拌机、旋转干燥机、其它流体输送机械。本发明方案可以作用于任何工作时会产出振动型号和/或声学信号的设备，并不局限于某一设备。为了更好说明本发明技术方案，以下以机械故障和流体力学故障进行说明，但并不局限于这两种故障类型。

优选的，机械故障和/或流体力学故障。

具体的，动设备的故障主要为两类，第一种便是机械故障类型，比如常见的轴承损坏、轴不对中、轴不平衡、泵基础或机械松动等，这些机械故障类型往往是动设备的结构性质发生损坏或改变，导致摩擦状态或振动状态改变，对应产出的声音也就主要是机械振动声音和摩擦声音。另一种便是流体动力异常状态，在生产车间中，机械动力传输和流体动力传输都十分常见，且流体也可能是产物

流动，当流体运转路径上存在故障时，例如汽蚀、湍流等，其也会发出对应的声音。频繁发生的汽蚀等故障会使离心泵产生异常的泵体振动、进出口压力脉动和噪声，影响泵性能、使用寿命和安全性。

动设备主要为滚动轴承。而滚动轴承的声学信号特点为：信号调制严重、故障信号微弱且信噪比低、信号频带宽、信号的周期性强。转动辐射噪声，所产生的噪声的峰值频率常常为离心泵转速的倍数，信号表现为周期性。而流体力学异常工况辐射的声学信号具有随机性。这两者的故障噪声特征存在巨大的特征差异，本发明方案便是针对该差异进行故障类型识别，以便于针对不同的故障类型指定对应的声学信号分析方法。

优选的，所述机械故障类型包括：轴承损坏、轴不对中、轴不平衡、泵基础松动和机械松动中的任意一种；所述流体力学异常类型包括：气蚀和湍流中的任意一种。

优选的，所述方法还包括：识别目标设备的设备类型；基于所述设备类型确定目标设备的检测信号特征；基于所述检测信号特征确定滤波规则，并基于所述滤波规则进行目标设备的检测信号采集。

在本发明方案中，设备类型差异，会导致信号存在差异，例如，但电动机，基于符合有储罐的电动机复合设备，二者的信号是存在信号特征差异的，本发明方案基于这种差异指定了对应的滤波采集方案，将大部分不属于目标设备信号特征频段的噪声信号过滤。

优选的，所述设备类型包括：机械动设备，包括往复型动设备和离心型动设备；空气动力学动设备，包括气体介质设备和液体介质设备。

优选的，所述基于自相关特性对所述检测信号进行故障类型分类，包括：基于检测信号自相关获得检测信号的不规则程度，并基于所述不规则程度判定产生当前检测信号的设备故障类型；基于确定的设备故障类型选定对应故障类型诊断模型。

具体的，所述基于检测信号自相关获得检测信号的不规则程度，包括：截取一段时间的检测信号，并对该段检测信号按照预设时移进行时移处理，获得对应的时移信号；基于该段检测信号和对应的时移信号构建自相关函数；计算所述自相关函数的熵；以该段检测信号的自相关函数的熵表征该段检测信号的不规则程度；其中，所述自相关函数的熵越小，不规则程度越大。

具体的，所述自相关函数的表达式为：

$$R_x(\tau) = \int_{-\infty}^{+\infty} x(t)x(t-\tau)dt$$

其中， t 为信号采集时刻； τ 为时移； $x(t)$ 为当前时间段内 t 时刻的检测信号； $x(t-\tau)$ 为当前时间段内 t 时刻检测信号的时移信号；所述自相关函数的熵的计算式为：

$$H = -c \sum_{x=1}^n R_x(\tau) * \log(R_x(\tau))$$

其中， c 为预设常数； H 为相关函数的熵。

实施例一：

声学信号自相关信号于其自身在不同时间点的互相关。对应的自相关函数

即两次观察之间的相似度对它们之间的时间差的函数。它是找出重复模式（如被噪声掩盖的周期信号），或识别隐含在信号谐波频率中消失的基频的数学工具。它常用于信号处理中，用来分析函数或一系列值，如时域信号。本发明方案想要识别声学信号是否存在规律性，便利用了自相关函数进行确定。具体的，截取一段时间的声学信号，并对该段声学信号基于预设时移进行时移处理，获得对应的时移信号；基于该段声学信号和对应的时移信号构建自相关函数；计算所述自相关函数的熵；以所述自相关函数的熵表征对应声学信号的不规则程度；其中，所述自相关函数的熵越大，对应声学信号的不规则程度越大。熵的本质是一个系统“内在的混乱程度”，在信号处理领域，其可以表示信号的不规则程度，熵值越小，对应的不规则程度也就越大，则信号就越不可能是规律信号。通过计算自相关函数的熵，用来表征信号的不规则程度，其中，自相关函数的表达式为：

$$R_x(\tau) = \int_{-\infty}^{+\infty} x(t)x(t-\tau)dt$$

其中， t 为信号采集时刻； τ 为时移； $x(t)$ 为 t 时刻的声学信号； $x(t-\tau)$ 为 t 时刻声学信号的时移信号。自相关函数的熵的计算式为：

$$H = -c \sum_{x=1}^n R_x(\tau) * \log(R_x(\tau))$$

其中， c 为预设常数； H 为相关函数的熵。

基于历史数据统计和相关人员的经验判断，可以进行熵值阈值标定，标定的标准为不大于该熵值的往往为流体力学异常类型，而大于该熵值的往往为机械故障类型。基于此，对比声学信号自相关函数熵与预设熵阈值；若自相关函数熵不大于预设熵阈值，则当前产生当前声学信号的设备故障类型为机械故障类型；其中，所述机械故障类型包括：轴承损坏、轴不对中、轴不平衡、泵基础松动和机械松动中的任意一种；若自相关函数熵大于预设熵阈值，则当前产生当前声学信号的设备故障类型为流体力学异常类型；其中，所述流体力学异常类型包括：气蚀和湍流中的任意一种。

步骤 S30：基于分类结果选择对应的故障诊断模型。

具体的，完成信号类型区分后，便可以基于信号区分结果进行适应性的故障诊断模型选择。

实施例二：

优选的，为了满足使用需求，后续故障识别时直接进行对应的故障识别模型调用，需要进行机械故障识别模型预训练。首先，对海量的历史运行数据进行筛选，筛选出标定为机械故障的运行数据，然后获得各数据对应的机械故障类型和声音采集历史信号。当然，这对于存在过基于声音监测进行故障识别方案的生成车间，其记录有对应的声音特征信号。若曾经未存在过声音监测信号，则对存在的机械故障的设备进行标定，然后基于每一个机械故障类型标定的设备进行运转并采集声音特征信息，将采集到的声音特征信息进行奇异谱和高阶谱融合分析处理，进行对应的特征提取。其中，奇异谱分析是近年来兴起的一种研究非线性时间序列数据的强大的方法。它根据所观测到的时间序列构造出轨迹矩阵，并对轨迹矩阵进行分解、重构，从而提取出代表原时间序列不同成分的信号，如长期趋势信号、周期信号、噪声信号等，从而对时间序列的结构进行分析，并可进一步预测。而高阶谱是高阶统计的一种表达形式，而高阶统计是统计特征阶数大于

2 的统计方法的广义定义。高阶统计作为一种非线性的信号处理工具，可以反映高阶相关的非线性关系。

在本发明实施例中，奇异谱分析效果主要体现在谱线平滑性及崩溃程度两个方面，与仅通过奇异谱进行特征提取的方法相比，融合高阶谱的奇异谱特征提取方法在相同嵌入维数（大量噪声条件下）图谱平滑性更好，且衰减也更快，崩溃现象也就越明显，即能够更好地反映维数特征。基于此，融合了高阶谱和奇异谱特征提取方案的特征提取效果更好，鲁棒性更强。

通过奇异谱和高阶谱融合分析处理后，提取去噪后的所述高阶谱数据中频域上的强度和相位特征，然后将该强度和相位特征作为入参，以对应的故障类型作为引导输出，进行机械故障类型识别模型训练，训练样本越大，对应训练获得的模型的效果也就符合预设。完成模型训练后，再选择一部分未使用的训练样本数据进行模型测试，判断模型训练结果是否符合预期。若符合预期，则可以将该训练获得的模型作为后续使用的机械故障识别模型。

实施例三：

进一步的，对于流体力学异常类型，因为其声学信号具有很强的随机性，所以流体噪声的处理及分析，相对比较复杂，通过手工特征提取难以实现准确识别。为了更好地进行流体力学异常类型声学信号特征提取，本发明方案提出了基于频谱图像视觉模型进行流体噪声处理的方法。频谱图简单理解为频率分布图，复杂的信号主要在于信号中包含了不同频率成分的信号。简单来说，通过傅里叶变化化无序为有序，然后基于频谱图进行具象表达。因为采集声声学信号为复杂信号，在复杂信号中，其实包含的信号频率是很多的，并不是单一的。

优选的，在本发明方案中，利用短时傅里叶变化对声学信号进行处理，短时傅里叶变换是一个用于语音信号处理的通用工具，它定义了一个非常有用的时间和频率分布类，其指定了任意信号随时间和频率变化的复数幅度。实际上，计算短时傅里叶变换的过程是把一个较长的时间信号分成相同长度的更短的段，在每个更短的段上计算傅里叶变换，即傅里叶频谱。因为基于短时傅里叶变化进行频谱图像模型构建的方法为现有方法，此处对其实施过程就不再赘述。将声学信号处理为图谱信号后，便基于该图谱信号作为对应的故障识别模型入参，该故障识别模型基于二维卷积构建，其构建方法与机械故障类型识别模型的构建方案类似，均是采集大量的历史数据和现有标定数据进行模型训练，当然，对应的训练样本数据也需要处理称为对应的频谱图像模型。

优选的，在故障识别模型训练过程中，通过图像数据增强的方式对频域信息直接施加干扰，对一定时间步长的频谱图像进行频移、扭转、遮蔽等处理，强迫识别模型做出细粒度表达，增强模型对干扰信息的处理能力，提高模型的泛化性能。

步骤 S40：基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。

具体的，对比一段检测信号的自相关函数的熵与预设熵阈值；若自相关函数的熵不大于预设熵阈值，则产生该段检测信号的设备故障类型为机械故障类型；若自相关函数的熵大于预设熵阈值，则产生该段检测信号的设备故障类型为流体力学异常类型。当前故障类型诊断模型为机械故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测信号进行奇异谱和高阶谱融合分析，获得分析后数据，作为特征信息；当前故障类型诊断模型为流体力学故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测

信号进行短时傅里叶变换处理, 获得对应的频谱图像, 作为特征信息。

具体的, 所述基于所述特征信息进行选择故障诊断模型训练, 基于训练结果进行故障设备识别, 包括: 将所述特征信息和运行工艺参数作为入参, 基于所述机械故障诊断模型进行训练, 将获得的训练结果作为机械故障类型分析结果; 或将所述特征信息和运行工艺参数作为入参, 执行所述流体力学故障诊断模型训练, 将获得的训练结果作为流体力学异常类型分析结果; 其中, 在流体力学异常识别模型训练过程中, 基于图像数据增强方法对训练过程进行干扰。

实施例四:

在各声音频率区段内, 获取各频段的声场云图信息, 并对比各频段的声场云图信息和预设标准声场云图信息, 获得各频段的声场云图偏离度; 基于各频段的声场云图偏离度获得总偏离度矩阵; 将所述总偏离度矩阵作为入参, 进行预设声场故障识别模型训练, 获得当前工况下的设备异常结果; 对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果, 进行当前故障诊断模型获得的设备异常结果验证。

具体的, 无论是机械故障类似识别结果, 还是流体动力异常类型识别结果, 最终均会基于对应的声音特征信息推测出产生该声音的故障类型信息, 将该故障类型信息直接推送到用户端, 可以辅助用户进行对应的故障识别和排查。

优选的, 为了保证进一步保证故障识别结果的准确性, 本发明方案还提出了故障诊断结果的验证方案。在各声音频率区段内, 获取各频段的声场云图信息, 并对比各频段的声场云图信息和预设标准声场云图信息, 获得各频段的声场云图偏离度; 基于各频段的声场云图偏离度获得总偏离度矩阵; 将所述总偏离度矩阵作为入参, 进行预设声场故障识别模型训练, 获得当前工况下的设备异常结果; 对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果, 进行当前故障诊断模型获得的设备异常结果验证。

具体的, 由于声音的传播具有叠加性, 现场复杂环境中的噪声往往是由多个声源叠加而成, 且声源发出声音的频谱特征变化、声源空间分布变化以及声源的增减, 都会导致固定检测点采集到的声音波形的变化。基于此, 本发明提出的验证方案基于声成像技术采集被测对象的噪声音频数据和声场视频数据, 通过分频段识别与判断, 对全频率范围内声音频谱特征与分布状态进行综合判别, 实现更加全面、准确、直观的多类型异常工作识别与可视化定位。

具体的, 首先需要获得对比方案的故障识别结果, 然后基于两个故障识别结果进行对比, 若二者之间差值符合预期, 则表示故障识别结果符合预期。若二者的差值超过预期, 则表示某一种方案存在识别错误, 则为了保证识别精准度, 需要进行重新故障识别尝试。

进行对比方案结果获得时, 首先需要构建对应的基于声场故障识别模型。当现场设备装置处于正常运行工况下, 使用声成像设备采集记录视频、音频信号, 建立正常运行工况样本库。步骤如下:

首先选定声音分析的总频率范围 $[\Phi_{\min}, \Phi_{\max}]$, 其中 $\Phi_{\max}$ 不大于麦克风采样频率的 1/2; 然后根据目标异常工况的噪声频率特征, 选定 N 组特征频率范围, 将总频率范围 $[\Phi_{\min}, \Phi_{\max}]$ 分为 N 组, 每组的频率范围为 $[\Phi_1, \Phi_2]$, $[\Phi_2, \Phi_3]$ …… $[\Phi_{N-1}, \Phi_N]$, 其中 $\Phi_1 = \Phi_{\min}$, $\Phi_N = \Phi_{\max}$; 接着设置第 1 组声音频率范围 $[\Phi_1, \Phi_2]$, 计算得到声场分布云图。记录最大声源点坐标 $\gamma_1[x_1, y_1]$; 进一步调整声音频率范围至第二组、第三组……第 N 组, 并重复上述步骤, 得到分频段声源点坐标 $\gamma_2[x_2, y_2]$ 、 $\gamma_3[x_3, y_3]$ …… $\gamma_N[x_N, y_N]$; 采集并储存麦克风阵列中某个麦克风的声

音能量信号 $s(t)$ ，对声学信号进行傅里叶变换并截取得到频率范围 $[\Phi_{\min}, \Phi_{\max}]$ 内的频谱密度 $s(w)$ ；按照之前设置的 N 组频率范围对总频谱密度进行过滤，得到 N 组特征频谱密度 $s_1(w)$ 、 $s_2(w)$ 、 $\dots$ 、 $s_N(w)$ ；保存最大声源点坐标 $\gamma_i[x_i, y_i]$ 、特征频谱密度 $s_i(w)$ 作为第 i 组频段的的声音特征参数，其中 $i=1、2、3\cdots\cdots N$ ；将各组特征频谱密度 $s_i(w)$ 作为输入，训练建立非监督识别模型；以各频段声音特征参数、非监督识别模型与声场云图视频为数据，建立正常运行工况样本库。

获得正常运行工况样本库后，非正常运行工况下，或使用模拟实验装置进行非正常工况的模拟实验时，使用声成像设备采集记录视频、音频信号，训练异常工况识别模型。步骤如下：

选定第 1 组声音分析频率范围 $[\Phi_1, \Phi_2]$ 内的频谱密度序列 $s_1(w)$ ，输入训练后的非监督识别模型，输出频率密度 $s'_{out}(w)$ ，计算频谱偏差率 $\theta_{s1} = \sum_{w=\Phi_1}^{\Phi_2} |s'_{out}(w) - s'(w)|$ ；采集声场云图中的最大声源点坐标 $\gamma'_i[x'_i, y'_i]$ ，与正常工况样本库中的对应频率范围内的正常坐标点 $\gamma_i[x_i, y_i]$ 进行对比，计算声源坐标偏离度 $\theta_{\gamma1} = \sqrt{(x'_i - x_i)^2 + (y'_i - y_i)^2}$ ；采集实测的声场云图视频，与正常工况样本库中的声场云图画面，逐帧进行图像相似度对比，取全部视频帧相似度的平均值，作为声场云图偏离度 $\theta_{\lambda1}$ ；组合得到第 1 组频率范围的偏离度矩阵 $\theta_1 = [\theta_{s1}, \theta_{\gamma1}, \theta_{\lambda1}]$ ，依次选择第 2 组至第 M 组频率范围，重复执行上述步骤，汇总得到总偏离度矩阵：

$$\theta = \begin{bmatrix} \theta_{s1} & \theta_{s2} & \theta_{sN} \\ \theta_{\gamma1} & \theta_{\gamma2} \cdots \theta_{\gamma N} \\ \theta_{\lambda1} & \theta_{\lambda2} & \theta_{\lambda N} \end{bmatrix}$$

以总偏离度矩阵作为输入，以异常工况的类型编号作为输出，训练建立异常工况识别模型。

获得基于声场故障识别模型后，将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果。对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证，二者一致性校验通过后，确定最终故障诊断结果。

实施例五：

人为标定多种类型的故障类型，包括轴承磨损、不对中、不平衡、机械松动、窜轴、基础松动、汽蚀、湍流。同一转动设备，同时仅标定一种故障类型，且在每一种故障类型下，分时段和分背景造成采集 200 组数据。最终每种故障类型均存在 200 组数据，共 1600 组数据，每组数据为声音信号或振动信号。进一步说明，该 1600 组数据包括多个预设点位的采集数据，该预设点位距离转动设备的距离和方位不同。将这些数据作为对比样本，形成多个对比例：

对比例一：隐藏每组数据的故障类型，将所有数据进行随机组合，获得故障类型未知和顺序序号错乱的数据组序列。基于仿真获得的基于振动信号的故障诊断模型进行故障检测，获得每组数据的诊断故障类型。然后显示对应数据隐藏的故障类型，进行二者对比，获得二者相同的数据组为 1420 组。

对比例二：

隐藏每组数据的故障类型，将所有数据进行随机组合，获得故障类型未知和顺序序号错乱的数据组序列。基于仿真获得的基于声学信号特征进行故障类型区分的故障诊断模型进行故障检测，获得每组数据的诊断故障类型。然后显示对应数据隐藏的故障类型，进行二者对比，获得二者相同的数据组为 1532 组。

对比例三：

隐藏每组数据的故障类型，将所有数据进行随机组合，获得故障类型未知和顺序序号错乱的数据组序列。基于仿真获得的基于声学信号特征进行故障类型区分的故障诊断模型进行故障检测，获得每组数据的诊断故障类型，并基于各频段的声场云图偏离度进行检测结果修正。对比修正后的检测结果和原始结果，获得二者相同的数据组为 1551 组。

图 2 是本发明一种实施方式提供的动设备故障检测装置的装置结构图。如图 2 所示，本发明实施方式提供一种动设备故障检测装置，所述装置包括：

信号采集模块，用于采集目标设备的检测信号。

具体的，本发明方案想要实现基于振动信号或者声学信号进行故障检测，因为声学信号和振动信号均是波形信号，二者在动设备正常工作状态下和异常工作状态下均会产生差异，所以本发明方面能够适用声学信号故障检测，同样也能适用振动信号故障检测。

优选的，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。

在本发明实施例中，除了采集需要的特诊信号以外，本发明方案还将采集设备的运行工艺参数。例如，某动设备还存在液体储罐，液体储罐内的液体存量，将会造成设备的信号产出差异，在进行故障诊断是，我们必须避免将这种因为设备工艺状态差异导致的信号差异误识别为故障信号特征差异。基于此，本发明方案进行模型构建和后续诊断训练时，都必须将设备的工艺参数作为一个参考量，从而保证识别结果的精准性。

需要明确的是，本发明方案理论上适用于任何方式的信号采集方案，无论是现有的人工巡检信号采集方案，还是固定或移动式传感器的信号采集方案，只要能够准确采集目标设备的信号特征，理论上都应属于本发明方案的保护范围。

信号分类模块，用于基于自相关特性对所述检测信号进行故障类型分类。

具体的，机械故障和流体力学故障。

具体的，动设备的故障主要为两类，第一种便是机械故障类型，比如常见的轴承损坏、轴不对中、轴不平衡、泵基础或机械松动等，这些机械故障类型往

往是动设备的结构性质发生损坏或改变,导致摩擦状态或振动状态改变,对应产生的声音也就主要是机械振动声音和摩擦声音。另一种便是流体动力异常状态,在生产车间中,机械动力传输和流体动力传输都十分常见,且流体也可能是产物流动,当流体运转路径上存在故障时,例如汽蚀、湍流等,其也会发出对应的声音。频繁发生的汽蚀等故障会使离心泵产生异常的泵体振动、进出口压力脉动和噪声,影响泵性能、使用寿命和安全性。

动设备主要为滚动轴承。而滚动轴承的声学信号特点为:信号调制严重、故障信号微弱且信噪比低、信号频带宽、信号的周期性强。转动辐射噪声,所产生的噪声的峰值频率常常为离心泵转速的倍数,信号表现为周期性。而流体力学异常工况辐射的声学信号具有随机性。这两者的故障噪声特征存在巨大的特征差异,本发明方案便是针对该差异进行故障类型识别,以便于针对不同的故障类型指定对应的声学信号分析方法。

优选的,所述机械故障类型包括:轴承损坏、轴不对中、轴不平衡、泵基础松动和机械松动中的任意一种;所述流体力学异常类型包括:气蚀和湍流中的任意一种。

优选的,所述方法还包括:识别目标设备的设备类型;基于所述设备类型确定目标设备的检测信号特征;基于所述检测信号特征确定滤波规则,并基于所述滤波规则进行目标设备的检测信号采集。

在本发明方案中,设备类型差异,会导致信号存在差异,例如,但电动机,基于符合有储罐的电动机复合设备,二者的信号是存在信号特征差异的,本发明方案基于这种差异指定了对应的滤波采集方案,将大部分不属于目标设备信号特征频段的噪声信号过滤。

优选的,所述设备类型包括:机械动设备,包括往复型动设备和离心型动设备;空气动力学动设备,包括气体介质设备和液体介质设备。

优选的,所述基于自相关特性对所述检测信号进行故障类型分类,包括:基于检测信号自相关获得检测信号的不规则程度,并基于所述不规则程度判定产生当前检测信号的设备故障类型;基于确定的设备故障类型选定对应故障类型诊断模型。

具体的,所述基于检测信号自相关获得检测信号的不规则程度,包括:截取一段时间的检测信号,并对该段检测信号按照预设时移进行时移处理,获得对应的时移信号;基于该段检测信号和对应的时移信号构建自相关函数;计算所述自相关函数的熵;以该段检测信号的自相关函数的熵表征该段检测信号的不规则程度;其中,所述自相关函数的熵越小,不规则程度越大。

具体的,所述自相关函数的表达式为:

$$R_x(\tau) = \int_{-\infty}^{+\infty} x(t)x(t-\tau)dt$$

其中, t 为信号采集时刻; τ 为时移; $x(t)$ 为当前时间段内 t 时刻的检测信号; $x(t-\tau)$ 为当前时间段内 t 时刻检测信号的时移信号;所述自相关函数的熵的计算式为:

$$H = -c \sum_{x=1}^n R_x(\tau) * \log(R_x(\tau))$$

其中, c 为预设常数; H 为相关函数的熵。

声学信号自相关信号于其自身在不同时间点的互相关。对应的自相关函数即两次观察之间的相似度对它们之间的时间差的函数。它是找出重复模式(如被噪声掩盖的周期信号), 或识别隐含在信号谐波频率中消失的基频的数学工具。它常用于信号处理中, 用来分析函数或一系列值, 如时域信号。本发明方案想要识别声学信号是否存在规律性, 便利用了自相关函数进行确定。具体的, 截取一段时间的声学信号, 并对该段声学信号基于预设时移进行时移处理, 获得对应的时移信号; 基于该段声学信号和对应的时移信号构建自相关函数; 计算所述自相关函数的熵; 以所述自相关函数的熵表征对应声学信号的不规则程度; 其中, 所述自相关函数的熵越大, 对应声学信号的不规则程度越大。熵的本质是一个系统“内在的混乱程度”, 在信号处理领域, 其可以表示信号的不规则程度, 熵值越小, 对应的不规则程度也就越大, 则信号就越不可能是规律信号。通过计算自相关函数的熵, 用来表征信号的不规则程度, 其中, 自相关函数的表达式为:

$$R_x(\tau) = \int_{-\infty}^{+\infty} x(t)x(t-\tau)dt$$

其中, t 为信号采集时刻; τ 为时移; $x(t)$ 为 t 时刻的声学信号; $x(t-\tau)$ 为 t 时刻声学信号的时移信号。自相关函数的熵的计算式为:

$$H = -c \sum_{x=1}^n R_x(\tau) * \log(R_x(\tau))$$

其中, c 为预设常数; H 为相关函数的熵。

基于历史数据统计和相关人员的经验判断, 可以进行熵值阈值标定, 标定的标准为不大于该熵值的往往为流体力学异常类型, 而大于该熵值的往往为机械故障类型。基于此, 对比声学信号自相关函数熵与预设熵阈值; 若自相关函数熵不大于预设熵阈值, 则当前产生当前声学信号的设备故障类型为机械故障类型; 其中, 所述机械故障类型包括: 轴承损坏、轴不对中、轴不平衡、泵基础松动和机械松动中的任意一种; 若自相关函数熵大于预设熵阈值, 则当前产生当前声学信号的设备故障类型为流体力学异常类型; 其中, 所述流体力学异常类型包括: 气蚀和湍流中的任意一种。

模型选择模块, 用于基于分类结果选择对应的故障诊断模型。

具体的, 完成信号类型区分后, 便可以基于信号区分结果进行适应性的故障诊断模型选择。

优选的, 为了满足使用需求, 后续故障识别时直接进行对应的故障识别模型调用, 需要进行机械故障识别模型预训练。首先, 对海量的历史运行数据进行筛选, 筛选出标定为机械故障的运行数据, 然后获得各数据对应的机械故障类型和声音采集历史信号。当然, 这对于存在过基于声音监测进行故障识别方案的生成车间, 其记录有对应的声音特征信号。若曾经未存在过声音监测信号, 则对存在的机械故障的设备进行标定, 然后基于每一个机械故障类型标定的设备进行运转并采集声音特征信息, 将采集到的声音特征信息进行奇异谱和高阶谱融合分析处理, 进行对应的特征提取。其中, 奇异谱分析是近年来兴起的一种研究非线性时间序列数据的强大的方法。它根据所观测到的时间序列构造出轨迹矩阵, 并对轨迹矩阵进行分解、重构, 从而提取出代表原时间序列不同成分的信号, 如长期趋势信号、周期信号、噪声信号等, 从而对时间序列的结构进行分析, 并可进一

步预测。而高阶谱是高阶统计的一种表达形式，而高阶统计是统计特征阶数大于2的统计方法的广义定义。高阶统计作为一种非线性的信号处理工具，可以反映高阶相关的非线性关系。

在本发明实施例中，奇异谱分析效果主要体现在谱线平滑性及崩溃程度两个方面，与仅通过奇异谱进行特征提取的方法相比，融合高阶谱的奇异谱特征提取方法在相同嵌入维数（大量噪声条件下）图谱平滑性更好，且衰减也更快，崩溃现象也就越明显，即能够更好地反映维数特征。基于此，融合了高阶谱和奇异谱特征提取方案的特征提取效果更好，鲁棒性更强。

通过奇异谱和高阶谱融合分析处理后，提取去噪后的所述高阶谱数据中频域上的强度和相位特征，然后将该强度和相位特征作为入参，以对应的故障类型作为引导输出，进行机械故障类型识别模型训练，训练样本越大，对应训练获得的模型的效果也就符合预设。完成模型训练后，再选择一部分未使用的训练样本数据进行模型测试，判断模型训练结果是否符合预期。若符合预期，则可以将该训练获得的模型作为后续使用的机械故障识别模型。

进一步的，对于流体力学异常类型，因为其声学信号具有很强的随机性，所以流体噪声的处理及分析，相对比较复杂，通过手工特征提取难以实现准确识别。为了更好地进行流体力学异常类型声学信号特征提取，本发明方案提出了基于频谱图像视觉模型进行流体噪声处理的方法。频谱图简单理解为频率分布图，复杂的信号主要在于信号中包含了不同频率成分的信号。简单来说，通过傅里叶变化化无序为有序，然后基于频谱图进行具象表达。因为采集声声学信号为复杂信号，在复杂信号中，其实包含的信号频率是很多的，并不是单一的。

优选的，在本发明方案中，利用短时傅里叶变化对声学信号进行处理，短时傅里叶变换是一个用于语音信号处理的通用工具，它定义了一个非常有用的时间和频率分布类，其指定了任意信号随时间和频率变化的复数幅度。实际上，计算短时傅里叶变换的过程是把一个较长的时间信号分成相同长度的更短的段，在每个更短的段上计算傅里叶变换，即傅里叶频谱。因为基于短时傅里叶变化进行频谱图像模型构建的方法为现有方法，此处对其实施过程就不再赘述。将声学信号处理为图谱信号后，便基于该图谱信号作为对应的故障识别模型入参，该故障识别模型基于二维卷积构建，其构建方法与机械故障类型识别模型的构建方案类似，均是采集大量的历史数据和现有标定数据进行模型训练，当然，对应的训练样本数据也需要处理称为对应的频谱图像模型。

优选的，在故障识别模型训练过程中，通过图像数据增强的方式对频域信息直接施加干扰，对一定时间步长的频谱图像进行频移、扭转、遮蔽等处理，强迫识别模型做出细粒度表达，增强模型对干扰信息的处理能力，提高模型的泛化性能。

故障诊断模块，用于基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。

具体的，对比一段检测信号的自相关函数的熵与预设熵阈值；若自相关函数的熵不大于预设熵阈值，则产生该段检测信号的设备故障类型为机械故障类型；若自相关函数的熵大于预设熵阈值，则产生该段检测信号的设备故障类型为流体力学异常类型。当前故障类型诊断模型为机械故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测信号进行奇异谱和高阶谱融合分析，获得分析后数据，作为特征信息；当前故障类型诊断模型为流体力学故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：对检测

信号进行短时傅里叶变换处理，获得对应的频谱图像，作为特征信息。

具体的，所述基于所述特征信息进行选择故障诊断模型训练，基于训练结果进行故障设备识别，包括：将所述特征信息和运行工艺参数作为入参，基于所述机械故障诊断模型进行训练，将获得的训练结果作为机械故障类型分析结果；或将所述特征信息和运行工艺参数作为入参，执行所述流体力学故障诊断模型训练，将获得的训练结果作为流体力学异常类型分析结果；其中，在流体力学异常识别模型训练过程中，基于图像数据增强方法对训练过程进行干扰。

在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；基于各频段的声场云图偏离度获得总偏离度矩阵；将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

具体的，无论是机械故障类似识别结果，还是流体动力异常类型识别结果，最终均会基于对应的声音特征信息推测出产生该声音的故障类型信息，将该故障类型信息直接推送到用户端，可以辅助用户进行对应的故障识别和排查。

优选的，为了进一步保证故障识别结果的准确性，本发明方案还提出了故障诊断结果的验证方案。在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；基于各频段的声场云图偏离度获得总偏离度矩阵；将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

具体的，由于声音的传播具有叠加性，现场复杂环境中的噪声往往是由多个声源叠加而成，且声源发出声音的频谱特征变化、声源空间分布变化以及声源的增减，都会导致固定检测点采集到的声音波形的变化。基于此，本发明提出的验证方案基于声成像技术采集被测对象的噪声音频数据和声场视频数据，通过分频段识别与判断，对全频率范围内声音频谱特征与分布状态进行综合判别，实现更加全面、准确、直观的多类型异常工作识别与可视化定位。

具体的，首先需要获得对比方案的故障识别结果，然后基于两个故障识别结果进行对比，若二者之间差值符合预期，则表示故障识别结果符合预期。若二者的差值超过预期，则表示某一种方案存在识别错误，则为了保证识别精准度，需要进行重新故障识别尝试。

本发明方案还提出一种动设备故障检测系统，所述系统包括上述的动设备故障检测装置。

本发明实施方式还提供一种计算机可读储存介质，该计算机可读存储介质上储存有指令，其在计算机上运行时使得计算机执行上述的动设备故障检测方法。

本领域技术人员可以理解实现上述实施方式的方法中的全部或部分步骤是可以通程序来指令相关的硬件来完成，该程序存储在一个存储介质中，包括若干指令用以使得单片机、芯片或处理器（processor）执行本发明各个实施方式所述方法的全部或部分步骤。而前述的存储介质包括：U 盘、移动硬盘、只读存储器（ROM, Read-Only Memory）、随机存取存储器（RAM, Random Access Memory）、磁碟或者光盘等各种可以存储程序代码的介质。

以上结合附图详细描述了本发明的可选实施方式，但是，本发明实施方式

并不限于上述实施方式中的具体细节，在本发明实施方式的技术构思范围内，可以对本发明实施方式的技术方案进行多种简单变型，这些简单变型均属于本发明实施方式的保护范围。另外需要说明的是，在上述具体实施方式中所描述的各个具体技术特征，在不矛盾的情况下，可以通过任何合适的方式进行组合。为了避免不必要的重复，本发明实施方式对各种可能的组合方式不再另行说明。

此外，本发明的各种不同的实施方式之间也可以进行任意组合，只要其不违背本发明实施方式的思想，其同样应当视为本发明实施方式所公开的内容。

权利要求书

- 1、一种动设备故障检测方法，其特征在于，所述方法包括：
采集目标设备的检测信号；
基于自相关特性对所述检测信号进行故障类型分类；
基于分类结果选择对应的故障诊断模型；
基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。
- 2、根据权利要求1所述的方法，其特征在于，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：
运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。
- 3、根据权利要求1所述的方法，其特征在于，所述动设备为工作时存在运动部件，且运动部件在工作时会产出振动信号和/或声学信号的设备。
- 4、根据权利要求3所述的方法，其特征在于，所述故障类型包括：
机械故障和/或流体力学故障。
- 5、根据权利要求1所述的方法，其特征在于，所述方法还包括：
识别目标设备的设备类型；
基于所述设备类型确定目标设备的检测信号特征；
基于所述检测信号特征确定滤波规则，并基于所述滤波规则进行目标设备的检测信号采集。
- 6、根据权利要求5所述的方法，其特征在于，所述设备类型包括：
机械动设备，包括往复型动设备和离心型动设备；
空气动力学动设备，包括气体介质设备和液体介质设备。
- 7、根据权利要求4所述的方法，其特征在于，所述基于自相关特性对所述检测信号进行故障类型分类，包括：
基于检测信号自相关获得检测信号的不规则程度，并基于所述不规则程度判定产生当前检测信号的设备故障类型；
基于确定的设备故障类型选定对应故障类型诊断模型。
- 8、根据权利要求7所述的方法，其特征在于，所述基于检测信号自相关获得检测信号的不规则程度，包括：
截取一段时间的检测信号，并对该段检测信号按照预设时移进行时移处理，获得对应的时移信号；
基于该段检测信号和对应的时移信号构建自相关函数；
计算所述自相关函数的熵；
以该段检测信号的自相关函数的熵表征该段检测信号的不规则程度；其中，所述自相关函数的熵越小，不规则程度越大。
- 9、根据权利要求8所述的方法，其特征在于，所述自相关函数的表达式为：

$$R_x(\tau)=\int_{-\infty}^{+\infty}x(t)x(t-\tau)dt$$

其中，t 为信号采集时刻；
 τ 为时移；

$x(t)$ 为当前时间段内 t 时刻的检测信号；

$x(t-\tau)$ 为当前时间段内 t 时刻检测信号的时移信号；

所述自相关函数的熵的计算式为：

$$H=-c\sum_{x=1}^nR_x(\tau)*\log(R_x(\tau))$$

其中，c 为预设常数；
H 为相关函数的熵。

- 10、根据权利要求 8 所述的方法，其特征在于，所述基于所述不规则程度判定产生各检测信号的设备故障类型，包括：
- 对比一段检测信号的自相关函数的熵与预设熵阈值；
- 若自相关函数的熵不大于预设熵阈值，则产生该段检测信号的设备故障类型为机械故障类型；
- 若自相关函数的熵大于预设熵阈值，则产生该段检测信号的设备故障类型为流体力学异常类型。

- 11、根据权利要求 10 所述的方法，其特征在于，当前故障类型诊断模型为机械故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：
- 对检测信号进行奇异谱和高阶谱融合分析，获得分析后数据，作为特征信息。

- 12、根据权利要求 10 所述的方法，其特征在于，当前故障类型诊断模型为流体力学故障诊断模型时，所述对所述检测信号进行特征提取，获得特征信息，包括：
- 对检测信号进行短时傅里叶变换处理，获得对应的频谱图像，作为特征信息。

- 13、根据权利要求 10 所述的方法，所述基于所述特征信息进行选择的故障诊断模型训练，基于训练结果进行故障设备识别，包括：
- 将所述特征信息和运行工艺参数作为入参，基于所述机械故障诊断模型进行训练，将获得的训练结果作为机械故障类型分析结果；或
- 将所述特征信息和运行工艺参数作为入参，执行所述流体力学故障诊断模型训练，将获得的训练结果作为流体力学异常类型分析结果；其中，
- 在流体力学异常识别模型训练过程中，基于图像数据增强方法对训练过程进行干扰。

- 14、根据权利要求 13 所述的方法，其特征在于，所述方法还包括：

训练机械故障诊断模型，包括：

对历史运行数据进行筛选，筛选出标定为机械故障的运行数据；

获得各数据对应的机械故障类型和历史检测信号；

将采集到的历史检测信号进行奇异谱和高阶谱融合分析处理，进行对应的特征提取，获得高阶谱数据中频域上的强度和相位特征；

将高阶谱数据中频域上的强度和相位特征作为入参，以对应的故障类型作为引导输出，进行机械故障类型识别模型训练，获得机械故障诊断模型。

15、根据权利要求 13 所述的方法，其特征在于，所述方法还包括：

训练流体力学故障诊断模型，包括：

对历史运行数据进行筛选，筛选出标定为流体力学故障的运行数据；

获得各数据对应的流体力学故障类型和历史检测信号；

将采集到的历史检测信号进行短时傅里叶变换处理，进行对应的特征提取，获得频谱图像；

将频谱图像入参，以对应的故障类型作为引导输出，进行流体力学故障类型识别模型训练，获得流体力学故障诊断模型。

16、根据权利要求 1 所述的方法，其特征在于，所述方法还包括：

在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；

基于各频段的声场云图偏离度获得总偏离度矩阵；

将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；

对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

17、一种动设备故障检测装置，其特征在于，所述装置包括：

信号采集模块，用于采集目标设备的检测信号；

信号分类模块，用于基于自相关特性对所述检测信号进行故障类型分类；

模型选择模块，用于基于分类结果选择对应的故障诊断模型；

故障诊断模块，用于基于选定的故障诊断模型和所述检测信号进行故障诊断，获得诊断结果。

18、根据权利要求 17 所述的装置，其特征在于，所述检测信号为声学信号和/或振动信号；以及目标设备的运行工艺参数；其中，所述运行工艺参数包括：

运行温度信息、压力信息、流量信息、固定方式信息中的一种或多种。

19、根据权利要求 17 所述的装置，其特征在于，所述动设备为工作时存在运动部件，且运动部件在工作时会产出振动信号和/或声学信号的设备。

20、根据权利要求 17 所述的装置，其特征在于，所述信号分类模块还用于：

识别目标设备的设备类型；

基于所述设备类型确定目标设备的检测信号特征；

基于所述检测信号特征确定滤波规则，并基于所述滤波规则进行目标设备

的检测信号采集。

21、根据权利要求 17 所述的装置，其特征在于，所述装置还包括验证模块，用于：

在各声音频率区段内，获取各频段的声场云图信息，并对比各频段的声场云图信息和预设标准声场云图信息，获得各频段的声场云图偏离度；

基于各频段的声场云图偏离度获得总偏离度矩阵；

将所述总偏离度矩阵作为入参，进行预设声场故障识别模型训练，获得当前工况下的设备异常结果；

对比基于声场故障识别模型获得的设备异常结果和基于故障诊断模型获得的设备异常结果，进行当前故障诊断模型获得的设备异常结果验证。

22、一种动设备故障检测系统，其特征在于，所述系统包括权利要求 17-21 所述的动设备故障检测装置。

23、一种计算机可读储存介质，该计算机可读储存介质上储存有指令，其在计算机上运行时使得计算机执行权利要求 1-16 中任一项权利要求所述的动设备故障检测方法。