



(12)发明专利

(10)授权公告号 CN 106408088 B

(45)授权公告日 2019.05.24

(21)申请号 201611027022.2

(22)申请日 2016.11.22

(65)同一申请的已公布的文献号  
申请公布号 CN 106408088 A

(43)申请公布日 2017.02.15

(73)专利权人 周孝忠  
地址 102206 北京市昌平区沙河镇百沙路  
青年创业大厦B817

(72)发明人 周孝忠

(74)专利代理机构 北京市合德专利事务所  
11244

代理人 王文会 刘榜美

(51)Int.Cl.  
G06N 3/08(2006.01)

(56)对比文件

CN 104238367 A,2014.12.24,  
CN 105241665 A,2016.01.13,  
CN 102788696 A,2012.11.21,  
CN 105241665 A,2016.01.13,  
US 2016162799 A1,2016.06.09,

审查员 田竞

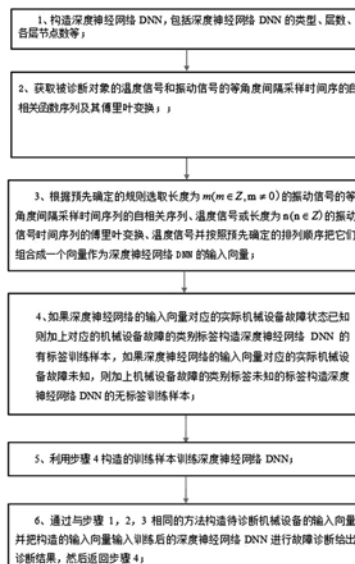
权利要求书2页 说明书6页 附图1页

(54)发明名称

一种基于深度学习理论的旋转机械设备故障诊断方法

(57)摘要

本发明涉及一种基于深度学习理论的旋转机械设备故障诊断方法。其通过用等时间间隔采样序列信号重构等角度间隔采样时间序列信号消除非匀速旋转造成的非平稳性,然后用等角度采样时间序列信号的自相关序列及其傅里叶变换和被诊断旋转机械设备工作时的温度作为深度神经网络的输入进行深度神经网络的训练和故障诊断,通过把新产生的数据及其对应的故障状态加入训练样本集,然后利用新的样本集再次对深度神经网络的训练实现深度神经网络DNN的自我学习与自我完善。



1. 一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:所述故障诊断方法包括如下步骤:

步骤1:构造深度神经网络DNN,其包括深度神经网络DNN的类型、层数、各层节点数;

步骤2:获取被诊断对象的温度信号和振动信号的等角度间隔采样时间序的自相关函数序列及其傅里叶变换,具体包括以下步骤:

1) 获取振动信号的等角度间隔采样时间序列和温度信号;

2) 对振动信号的等角度间隔采样时间序列进行自相关得到其自相关函数序列;

3) 求振动信号的等角度间隔采样时间序列或振动信号的等角度间隔采样时间序列自相关函数的傅里叶变换;

步骤3:根据预先确定的规则选取长度为 $m$  ( $m \in Z, m \neq 0$ ) 的振动信号的等角度间隔采样时间序列的自相关序列、温度信号或长度为 $n$  ( $n \in Z$ ) 的振动信号时间序列的傅里叶变换、温度信号并按照预先确定的排列顺序把它们组合成一个向量作为深度神经网络DNN的输入向量,所述预先确定的规则包括:只选取长度为 $m$  ( $m \in Z, m \neq 0$ ) 的振动信号的等角度采样时间序列的自相关函数序列,选取长度为 $m$  ( $m \in Z, m \neq 0$ ) 的振动信号的等角度采样时间序列的自相关函数序列和温度信号,选取长度为 $m$  ( $m \in Z, m \neq 0$ ) 的振动信号的等角度采样时间序列的自相关函数序列和长度为 $n$  ( $n \in Z$ ) 的傅里叶变换,选取长度为 $m$  ( $m \in Z, m \neq 0$ ) 的振动信号的等角度采样时间序列的自相关函数序列、温度信号和长度为 $n$  ( $n \in Z$ ) 的傅里叶变换,选取长度为 $n$  ( $n \in Z$ ) 的等角度采样时间序列的傅里叶变换、温度信号;选取长度为 $n$  ( $n \in Z$ ) 的傅里叶变换;

步骤4:如果深度神经网络的输入向量对应的实际机械设备故障状态已知则加上对应的机械设备故障的类别标签构造深度神经网络DNN的有标签训练样本,如果深度神经网络的输入向量对应的实际机械设备故障未知,则加上机械设备故障的类别标签未知的标签构造深度神经网络DNN的无标签训练样本;

步骤5:利用步骤4构造的训练样本训练深度神经网络DNN,具体包括下列步骤:

1) 用无标签训练样本或有标签训练样本通过无监督学习的方式逐层训练深度神经网络DNN的隐层;

2) 添加深度神经网络DNN的输出层,然后用有标签训练样本,微调深度神经网络DNN参数完成DNN的训练;

步骤6:通过与步骤1,2,3相同的方法构造待诊断机械设备的输入向量并把构造的输入向量输入训练后的深度神经网络DNN进行故障诊断给出诊断结果,然后返回步骤4。

2. 根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:步骤1所述的深度神经网络的类型包括:自动编码器 (AutoEncoder)、降噪自动编码器 (Denoising Autoencode)、稀疏编码 (Sparse coding)、限制波尔兹曼机 (Restricted Boltzmann Machine)、深信度网络 (Deep Belief Networks)、卷积神经网络 (Convolutional Neural Networks)。

3. 根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:步骤4所述的实际机械设备故障状态包括:有无故障、故障位置、故障严重程度。

4. 根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:所述步骤3中获取机械设备振动信号的等角度间隔采样时间序列和温度信号具体

为:通过角度传感器控制的采样电路或先进行等时间间隔采样然后再利用计算阶次跟踪技术得到等角度间隔采样时间序列的方法得到振动信号的等角度间隔采样时间序列,利用温度传感器检测振动设备的温度获取温度信号。

5.根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:所述步骤3中采用时域自相关算法或频域自相关算法求取振动信号的等角度间隔采样时间序列自相关函数序列。

6.根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:采用FFT算法软件求取振动信号的等角度间隔采样时间序列的傅里叶变换或振动信号的等角度间隔采样时间序列自相关函数的傅里叶变换。

7.根据权利要求1所述的一种基于深度学习理论的旋转机械设备故障诊断方法,其特征在于:所述步骤5中用无标签训练样本或有标签训练样本通过无监督学习的方式逐层训练深度神经网络DNN的隐层,具体为:

给定一个无标签的机械健康状况样本集  $X^M = \{x^m\}_{m=1}^M$ , 对样本  $x^m$  按照  $q_D$  分布加入随机噪声,使其变成含噪声样本  $\tilde{x}^m$ , 即  $\tilde{x}^m \sim q_D(\tilde{x}^m | x^m)$  式中,  $q_D$  为二项随机隐藏噪声,也就是说对于每个输入向量  $x^m$  按照一定摧毁率随机选择向量的元素将该元素的值重置为零,每一个加入随机噪声的无标签的机械健康状况样本组成含噪声无标签的机械健康状况样本集  $\tilde{X}^M = \{\tilde{x}^m\}_{m=1}^M$ , 编码网络通过编码函数将每一个训练样本变换为编码矢量  $\tilde{h}^m = f_\alpha(\tilde{x}^m) = s_f(W\tilde{x}^m + b)$ , 式中,  $s_f$  为编码网络的激活函数本实施例  $s_f(x) = \frac{1}{1+e^{-x}}$ ;  $\alpha$  为编码网络的参数集合,且  $\alpha = \{W, b\}$ , 然后编码矢量通过解码函数  $g_{\alpha'}$  反向变换为  $x^m$  的一种重构表示;  $\hat{x}^m = g_{\alpha'}(\tilde{h}^m) = s_g(W'\tilde{h}^m + d)$  式中,  $s_g$  为解码网络的激活函数;  $\alpha'$  为解码网络的参数集合,且  $\alpha' = \{W', d\}$ , 自动编码器通过最小化  $x^m$  与  $\hat{x}^m$  的重构误差  $L(x, \hat{x})$ , 完成整个网络的训练,  $L(x, \hat{x}) = \frac{1}{M} \|x - \hat{x}\|^2$ , DNN训练的算法核心是用无监督的方法将多个降噪自动编码器层层堆叠形成DNN隐层结构,首先使用样本集  $\tilde{X}^M$  训练降噪自动编码器第一层DAE1,并将其编码为  $\tilde{h}_1^m = f_{\alpha_1}(\tilde{x}^m)$  式中,  $\alpha_1$  为DAE1的参数, 因为  $\tilde{h}_1^m$  可以重构为输入样本,所以获得了  $\tilde{x}^m$  的主要信息,然后使用  $\tilde{h}_1^m$  训练降噪自动编码器第二层DAE2,并将输入编码为  $\tilde{h}_2^m$ , 重复这个过程,直到降噪自动编码器第6层DAE6训练完毕,并将输入编码为  $\tilde{h}_6^m = f_{\alpha_6}(\tilde{h}_5^m)$ , 预训练将多个DAE相互连接起来,组成DNN隐层结构,实现故障信息的层层提取。

## 一种基于深度学习理论的旋转机械设备故障诊断方法

### 技术领域

[0001] 本发明涉及旋转机械设备故障诊断,特别是涉及一种基于深度学习理论的旋转机械设备故障诊断方法。

### 背景技术

[0002] 随着现代工业和科学技术的发展以及自动化程度的进一步提高,机械设备正朝着大型化、高速化、连续化、集中化、自动化方向发展。旋转机械设备长期处于高速运行状态(一般为每分钟3000转以上甚至高达几万转),由于各种因素的影响,难免会出现一些故障,而且这些故障往往会引起巨大的经济损失甚至灾难性后果,因此对旋转机械设备故障诊断十分重要。振动检测诊断法是当今旋转机械设备故障诊断技术的最常用的诊断方法。振动信号包含了丰富的机械运行状态信息,所以振动检测诊断法可以对机械设备中的大部分故障类型进行准确的诊断。目前在工程应用中采用的振动分析方法主要有时域分析法和频域分析法。时域分析法主要是在信号的时域提取故障的时域特征然后根据时域特征的变化对机械设备进行故障诊断的技术。频域分析法是通过傅里叶变换把振动信号变换到频域进行分析,提取信号频域特征然后根据频域特征的变化对机械设备进行故障诊断的技术。现有时域分析法算法简单、快捷、能判断机械设备是否有故障以及故障的严重程度,但由于时域故障部位和类型特征模式复杂提取不易,所以判断故障部位和故障类型困难。频域分析法能判定是否有故障及故障部位和类型,所以精细诊断多采用频域分析法,但频域分析法无法判定故障的严重程度且对振动信号的非平稳性敏感,若对这些非平稳信号直接进行傅立叶分析将产生严重的频率模糊现象,从而影响故障的判断。另外,采用现有“基于信号处理的特征提取+机器学习模型”方法进行特征提取需要掌握大量的信号处理技术结合丰富的工程实践经验才能完成,并且没有考虑特征提取与智能诊断两个环节之间的关系模型,训练使用浅层模型表征信号与健康状况之间复杂的映射关系,导致面对机械大数据时,模型的监测诊断能力及泛化性能均有明显不足,很难满足大数据背景下机械故障诊断的实际需求。为克服这些缺陷文献【“基于深度学习理论的机械装备大数据健康监测方法”,机械工程学报2015年第51卷第21期】提出了一种“基于深度学习理论的机械装备大数据健康监测方法”,该方法通过构建具有很多隐层的机器学习模型和海量的训练数据,来学习机械设备故障更有用的特征,从而最终提升诊断和预测的准确性。与人工规则构造特征的方法相比,利用大数据来学习特征,更能够刻画数据的丰富内在信息。但该方法只利用振动信号的频域特征,没有克服振动非平稳性引起的频率模糊现象,也没有利用振动信号的时域信息和与故障相关性很强的被监测对象的温度信息,所以对非匀转速场景效果不理想,也无法判断故障严重程度。另外,该方法也没有给出对所构造的深度神经网络进行自我学习、自我完善的方法。

### 发明内容

[0003] 针对现有方法的不足,本发明提供了一种基于深度学习理论的旋转机械设备故障

诊断方法。通过用等时间间隔采样序列信号重构等角度间隔采样时间序列信号消除非匀速旋转造成的非平稳性,然后用等角度采样时间序列信号的自相关序列、等角度采样时间序列信号傅里叶变换和被诊断旋转机械设备工作时的温度作为深度神经网络的输入进行深度神经网络的训练和故障诊断,通过把新产生的数据及其对应的故障状态加入训练样本集,然后利用新的样本集再次对深度神经网络的训练实现深度神经网络DNN的自我学习与自我完善。

[0004] 该方法克服了现有方法的不足,不但能消除非匀速旋转造成的非平稳性,通过利用时域信息和温度信息使诊断结果更精准,而且能够实现深度神经网络模型自我学习和自我完善。

[0005] 本发明的目的是一种基于深度学习的理论旋转机械设备故障诊断方法,用以解决上述现有技术的缺陷。

[0006] 为了达到上述目的,本发明所提供的技术方案是:基于深度学习理论的旋转机械设备故障诊断方法,它包括

[0007] 1、构造深度神经网络DNN,包括深度神经网络DNN的类型、层数、各层节点数等;

[0008] 2、获取被诊断对象的温度信号和振动信号的等角度间隔采样时间序的自相关函数序列及其傅里叶变换;

[0009] 3、根据预先确定的规则选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度间隔采样时间序列的自相关序列、温度信号或长度为  $n(n \in \mathbb{Z})$  的振动信号时间序列的傅里叶变换、温度信号并按照预先确定的排列顺序把它们组合成一个向量作为深度神经网络DNN的输入向量;

[0010] 4、如果深度神经网络的输入向量对应的实际机械设备故障状态已知则加上对应的机械设备故障的类别标签构造深度神经网络DNN的有标签训练样本,如果深度神经网络的输入向量对应的实际机械设备故障未知,则加上机械设备故障的类别标签未知的标签构造深度神经网络DNN的无标签训练样本;

[0011] 5、利用步骤4构造的训练样本训练深度神经网络DNN;

[0012] 6、通过与步骤1,2,3相同的方法构造待诊断机械设备的输入向量并把构造的输入向量输入训练后的深度神经网络DNN进行故障诊断给出诊断结果,然后返回步骤4;

[0013] 进一步的步骤1所述的深度神经网络的类型包括:自动编码器AutoEncoder、降噪自动编码器 Denoising Autoencode、稀疏编码Sparse coding、限制波尔兹曼机 Restricted Boltzmann Machine (RBM)、深信度网络Deep Belief Networks、卷积神经网络Convolutional Neural Networks;

[0014] 进一步的步骤2又包括以下步骤:

[0015] 1)、获取振动信号的等角度间隔采样时间序列和温度信号、

[0016] 2)、对振动信号的等角度间隔采样时间序列进行自相关得到其自相关函数序列;

[0017] 3)、求振动信号的等角度间隔采样时间序列或振动信号的等角度间隔采样时间序列自相关函数的傅里叶变换;

[0018] 进一步的步骤3所述预先确定的规则包括:只选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信

号的等角度采样时间序列的自相关函数序列和温度信号,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列和长度为  $n(n \in \mathbb{Z})$  的傅里叶变换,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列、温度信号和长度为  $n(n \in \mathbb{Z})$  的傅里叶变换,选取长度为  $n(n \in \mathbb{Z})$  的等角度采样时间序列的傅里叶变换、温度信号;选取长度为  $n(n \in \mathbb{Z})$  的傅里叶变换;

[0019] 进一步的步骤4所述的实际机械设备故障状态包括:有无故障、故障位置、故障严重程度;

[0020] 进一步的步骤5又包括下列步骤:

[0021] 1)、用无标签训练样本或有标签训练样本通过无监督学习的方式逐层训练深度神经网络DNN的隐层;

[0022] 2)、添加深度神经网络DNN的输出层,然后用有标签训练样本,微调深度神经网络DNN参数完成DNN的训练;

[0023] 采用上述技术方案,本发明的技术效果有:本发明的故障故障诊断方法通过用等时间间隔采样序列信号重构等角度间隔采样时间序列信号消除非匀速旋转造成的非平稳性,通过采用深度学习算法实现故障诊断的自我学习和自我进化使诊断结果更为准确。

## 附图说明

[0024] 图1是本发明的逻辑结构示意图;

## 具体实施方式

[0025] 下面结合附图以某型风电机组的轴承故障诊断为例说明本发明的具体实施方式。

[0026] 1、构造深度神经网络DNN,包括深度神经网络DNN的类型、层数、各层节点数;

[0027] 进一步的步骤1所述的深度神经网络的类型包括:自动编码器AutoEncoder、去噪自动编码器 Denoising Autoencode、稀疏编码Sparse coding、限制波尔兹曼机 Restricted Boltzmann Machine (RBM)、深信度网络Deep Belief Networks、卷积神经网络Convolutional Neural Networks;

[0028] 根据机械故障振动信号的特点,本实施例选用具有7层去噪自动编码器 Denoising Autoencode、每层节点数2097170个。

[0029] 因为机械设备所处环境复杂,样本数据易于受到干扰,再加上复杂任务带来的工况变化,导致相同健康状况下的样本的性质会有所波动。降噪自动编码器通过重构含有噪声的样本数据增强了DNN的鲁棒性。其核心思想是:编码网络将含有一定统计特性的噪声加入样本数据,然后对样本进行编码,解码网络再根据噪声统计特性从未受到干扰的数据中估计出受干扰样本的原始形式,从而使降噪自动编码器从含噪声样本中学习到更具鲁棒性的特征,降低噪自动编码器对微小随机扰动的敏感性。降噪自动编码器的原理类似于人体的感官系统,比如人眼看物体时,如果某一小部分被遮住了,人依然可以辨识出该物体。同理,降噪自动编码器通过添加噪声进行编码重构,可有效减小机械工况变化与环境噪声等随机因素对提取的健康状况信息的影响,提高特征表达的鲁棒性。

[0030] 2、获取被诊断对象的温度信号和振动信号的等角度间隔采样时间序的自相关函数序列及其傅里叶变换;

[0031] 进一步的步骤2又包括以下步骤:

[0032] 1)、获取机械设备振动信号的等角度间隔采样时间序列和温度信号。

[0033] 通过角度传感器控制的采样电路或先进行等时间间隔采样然后再利用计算阶次跟踪技术得到等角度间隔采样时间序列的方法得到振动信号的等角度间隔采样时间序列,利用温度传感器检测振动设备的温度获取温度信号;本实施例首先采用振动传感器和转速传感器检测机械设备的振动和转速,其次对振动传感器输出的振动信号和转速传感器输出的转速信号进行等时间间隔同步采样,再次利用计算阶次跟踪技术得到振动信号的等角度间隔采样时间序列;

[0034] 2)、对振动信号的等角度间隔采样时间序列进行自相关得到其自相关函数序列;

[0035] 采用时域自相关算法或频域自相关算法求取振动信号的等角度间隔采样时间序列自相关函数序列;本实施例中采用时域自相关算法软件计算振动信号的等角度间隔采样时间序列自相关函数序列;

[0036] 3)、求振动信号的等角度间隔采样时间序列或振动信号的等角度间隔采样时间序列自相关函数的傅里叶变换;

[0037] 本实施例中采用FFT算法软件求取振动信号的等角度间隔采样时间序列的傅里叶变换或振动信号的等角度间隔采样时间序列自相关函数的傅里叶变换;

[0038] 3、根据预先确定的规则选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号时间序列、温度信号、机械设备的参数、长度为  $n(n \in \mathbb{Z})$  的振动信号时间序列的傅里叶变换并按照预先确定的排列顺序把它们组合成一个向量作为深度神经网络DNN的输入向量;

[0039] 所述预先确定的规则包括:只选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列和温度信号,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列和长度为  $n(n \in \mathbb{Z})$  的等角度采样时间序列的傅里叶变换,选取长度为  $m(m \in \mathbb{Z}, m \neq 0)$  的振动信号的等角度采样时间序列的自相关函数序列、温度信号和长度为  $n(n \in \mathbb{Z})$  的等角度采样时间序列的傅里叶变换,选取长度为  $n(n \in \mathbb{Z})$  的等角度采样时间序列的傅里叶变换、温度信号;选取长度为  $n(n \in \mathbb{Z})$  的等角度采样时间序列的傅里叶变换;

[0040] 本实施例中选取长度为  $m=1048576$  的振动信号的等角度采样时间序列的自相关函数序列、1个温度信号,按照1个温度信号、1048576个振动信号的等角度采样时间序列的自相关函数序列样点顺序组合成一个向量作为深度神经网络DNN的输入向量。

[0041] 4、如果深度神经网络的输入向量对应的实际机械设备故障状态已知则加上对应的机械设备故障的类别标签构造深度神经网络DNN的有标签训练样本,如果深度神经网络的输入向量对应的实际机械设备故障未知,则加上机械设备故障的类别标签未知的标签构造深度神经网络DNN的无标签训练样本;

[0042] 本实施例中,实际机械设备(轴承)的故障状态分为正常、保持架故障、外圈故障、内圈故障、滚动体故障、和5种转子故障,每种故障的故障严重程度又分为1到9九级共有82种故障状态,每一种故障状态给予4个输出共有16个编码。

[0043] 5、利用步骤4构造的训练样本训练深度神经网络DNN;

[0044] 1)、用无标签训练样本或有标签训练样本通过无监督学习的方式逐层训练深度神经网络DNN的隐层；

[0045] 给定一个无标签的机械健康状况样本集  $X^M = \{x^m\}_{m=1}^M$ ，对样本  $x^m$  按照  $Q_D$  分布加入随机噪声，使其变成含噪声样本  $\tilde{x}^m$ ，即  $\tilde{x}^m \sim q_D(\tilde{x}^m | x^m)$  式中， $Q_D$  为二项随机隐藏噪声。也就是说对于每个输入向量  $x^m$  按照一定摧毁率随机选择向量的元素把该元素的值重置为零。每一个加入随机噪声的无标签的机械健康状况样本组成含噪声无标签的机械健康状况样本集  $\tilde{X}^M = \{\tilde{x}^m\}_{m=1}^M$  编码网络通过编码函数将每一个训练样本变换为编码矢量  $\tilde{h}^m = f_\alpha(\tilde{x}^m) = s_f(W\tilde{x}^m + b)$ 。式中， $s_f$  为编码网络的激活函数本实施例  $s_f(x) = \frac{1}{1+e^{-x}}$ ； $\alpha$  为编码网络的参数集合，且  $\alpha = \{W, b\}$ 。然后编码矢量  $\tilde{h}^m$  通过解码函数  $g_\alpha$  反向变换为  $x^m$  的一种重构表示。 $\hat{x}^m = g_\alpha(\tilde{h}^m) = s_g(W'\tilde{h}^m + d)$  式中， $s_g$  为解码网络的激活函数； $\alpha'$  为解码网络的参数集合，且  $\alpha' = \{W', d\}$ 。自动编码器通过最小化  $x^m$  与  $\hat{x}^m$  的重构误差  $L(x, \hat{x})$ ，完成整个网络的训练。 $L(x, \hat{x}) = \frac{1}{M} \|x - \hat{x}\|^2$  DNN 训练的算法核心是用无监督的方法将多个降噪自动编码器层层堆叠形成 DNN 隐层结构，首先使用样本集  $\tilde{X}^M$  训练降噪自动编码器第一层 DAE1，并将其编码为  $\tilde{h}_1^m = f_{\alpha_1}(\tilde{x}^m)$  式中， $\alpha_1$  为 DAE1 的参数。因为  $\tilde{h}_1^m$  可以重构为输入样本，所以获得了  $\tilde{x}^m$  的主要信息。然后使用  $\tilde{h}_1^m$  训练降噪自动编码器第二层 DAE2，并将输入编码为  $\tilde{h}_2^m$ 。重复这个过程，直到降噪自动编码器第6层 DAE6 训练完毕，并将输入编码为  $\tilde{h}_6^m = f_{\alpha_6}(\tilde{h}_5^m)$ 。预训练将多个 DAE 相互连接起来，组成 DNN 隐层结构，实现故障信息的层层提取。

[0046] 2)、添加深度神经网络DNN的输出层，然后用有标签训练样本，微调深度神经网络DNN参数完成DNN的训练；

[0047] 完成预训练后，为了监测诊断机械的健康状况，添加具有分类功能的输出层，本实施例中用支持向量机SVM作为DNN的输出层，使用BP算法微调DNN参数。

[0048] DNN的输出表示为  $z^m = f_{\alpha_7}(\tilde{h}_6^m)$  式中， $\alpha_7$ ，为输出层的参数。设的健康状况类型为  $d^m$ ，DNN通过最小化  $A_{DNN}(\alpha)$  完成微调。

[0049]  $\Theta_{DNN}(A) = \frac{1}{M} \sum_{m=1}^M L(z^m, d^m)$  式中，A为DNN的参数集，且  $A = \{\alpha_1, \alpha_2, \dots, \alpha_7\}$  经过微调的DNN优化了对机械健康状况信息的特征表示，并具备了机械健康状况的监测诊断能力。



[0050] 6、通过与步骤1,2,3相同的方法构造待诊断机械设备的输入向量并把构造的输入向量输入训练后的深度神经网络DNN进行故障诊断给出诊断结果,然后返回步骤4;

[0051] 深度神经网络DNN训练完成后就可用其进行机械设备的故障诊断了,诊断的流程与方法中的步骤1到步骤3的流程相同。诊断完成后给出诊断结果,必要时还可把诊断结果通过互联网呈现给指定的相关人员,通过网络呈现给指定的相关人员的方法和技术与现在普遍采用的方法和技术相同。输出诊断结果后通过维修保养过程对被诊断对象进行实际拆装实际验证诊断的结果是否与实际一致,然后返回到步骤4采用新的实际产生的样本再次对DNN进行训练,这样经过反复的进行训练、诊断、验证、再训练、再诊断、再验证的循环往复的过程完成DNN的自我学习和自我训练,使得DNN的诊断结果越来越准确,越来越符合实际。

[0052] 最后应说明的是,以上实施例仅用以说明本发明的技术方案而非限制,尽管参照较佳实施例对本发明进行了详细说明,本领域的普通技术人员应当理解,可以对本发明的技术方案进行修改或者等同替换,而不脱离本发明技术方案的精神和范围,其均应涵盖在本发明的权利要求范围当中。

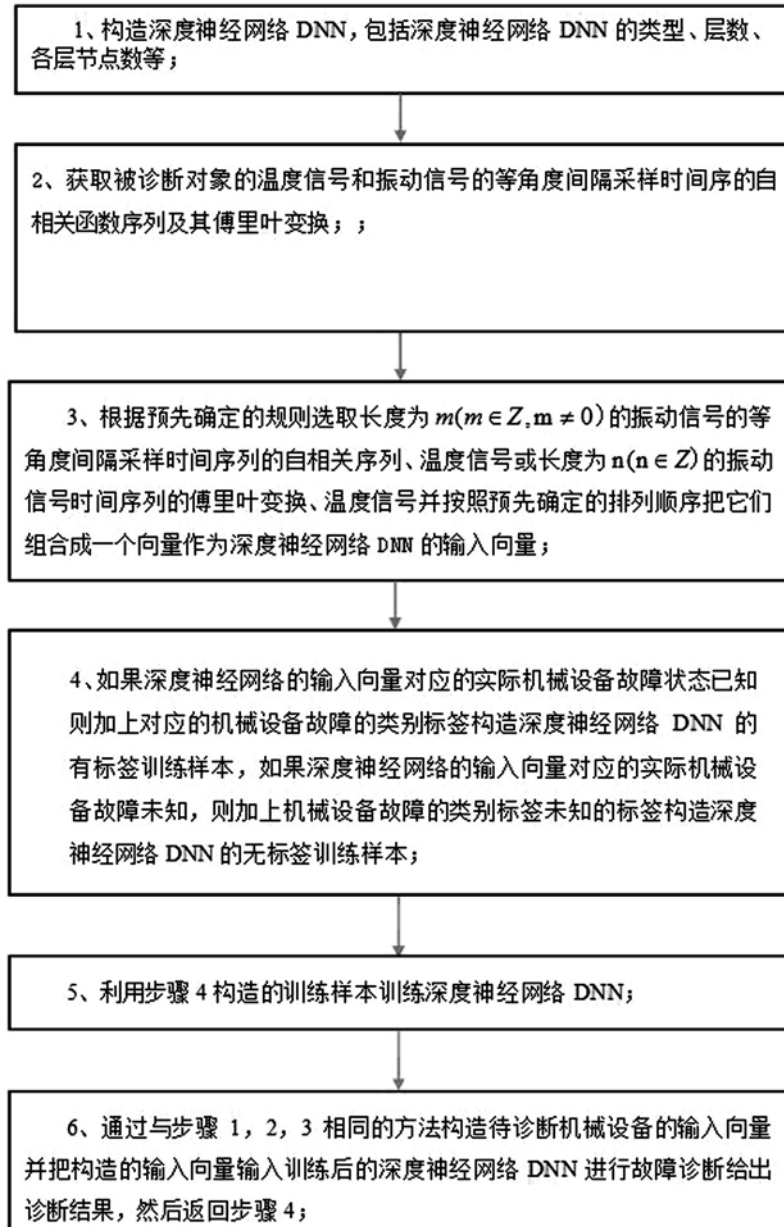


图1