



## (12) 发明专利申请

(10) 申请公布号 CN 104634603 A

(43) 申请公布日 2015. 05. 20

(21) 申请号 201510114270. X

(22) 申请日 2015. 03. 16

(71) 申请人 汪文峰

地址 247100 安徽省池州市东至县洋湖镇洋湖村西边组 19 号

(72) 发明人 汪文峰

(74) 专利代理机构 北京科亿知识产权代理事务所 (普通合伙) 11350

代理人 汤东风

(51) Int. Cl.

G01M 99/00(2011. 01)


权利要求书1页 说明书6页 附图4页

### (54) 发明名称

一种复杂设备早期故障诊断方法

### (57) 摘要

本发明公开了一种复杂设备早期故障诊断方法,具体步骤包括:通过传感器提取采集信号;对提取采集的信号进行小波变换去噪;就机械特征和电路特征分别建立基于 BP 神经网络的故障诊断模型和基于 SVM 的故障诊断模型,进行故障诊断。基于 SVM 的故障诊断模型中核函数为多项式核函数、径向基核函数 RBF 或 Sigmoid 核函数。本发明将复杂设备的故障诊断分为机械特征的故障诊断和电路特征的故障诊断,就机械特征和电路特征分别建立故障诊断模型,机械易试验,可获样本多,运用 BP 神经网络收敛快,准确度较高;而电路样本数据少,运用 SVM 的小样本优势,从而实现复杂设备等复杂系统的故障诊断。



1. 一种复杂设备早期故障诊断方法,其特征在于,具体步骤如下:

(1) 通过传感器提取采集信号;

(2) 对提取采集的信号进行小波变换去噪;

(3) 就机械特征和电路特征分别建立基于 BP 神经网络的故障诊断模型和基于 SVM 的故障诊断模型,进行故障诊断。

2. 根据权利要求 1 所述的复杂设备早期故障诊断方法,其特征在于,所述基于 BP 神经网络的故障诊断模型进行故障诊断的方法,具体步骤如下:

(1) 所述传感器连接在机械设备上提取采集信号;

(2) 将提取采集的信号进行小波变换去噪处理后分别进行原始数据诊断和样本数据训练,再进入 BP 神经网络分别进行预处理和特征选择/提取;

(3) 原始数据经预处理和特征选择/提取后再经过 BP 神经网络诊断得到诊断结果,样本数据经过预处理和特征选择/提取后进行学习训练;

(4) 对于得到的诊断结果进行诊断决策,再分别进行定期维修、视情维修和事后维修。

3. 根据权利要求 1 所述的复杂设备早期故障诊断方法,其特征在于,所述基于 SVM 的故障诊断模型中核函数为多项式核函数、径向基核函数 RBF 或 Sigmoid 核函数。

## 一种复杂设备早期故障诊断方法

### 技术领域

[0001] 本发明涉及一种故障诊断方法,具体是一种复杂设备早期故障诊断方法。

### 背景技术

[0002] 故障诊断主要是指对设备状态进行监测和故障的判定,不仅需要对设备发生故障的原因、位置、程度做出正确的判断,进而进行预防,降低故障损失,还需要监测设备的健康状态,特别对早期故障的监测,尽早进行预警判断,减少突发故障的发生,也可以预测未来故障的发生时间,这样可以充分节约维修资源,也为设备维护、保养提供最佳维修决策依据,特别为视情维修策略的实现提供可能性。

[0003] 故障诊断从技术上而言,实际上是在一定的故障判断策略的指导下,对监测诊断设备实施自动检测,也就是通过分析构建获取设备的故障模型,提取故障特征,然后根据预定的策略、原则,对监测到的信息进行综合评估,最后对维护人员提示必要的维修措施。因此,故障诊断不仅需要现代控制论、计算机科学、人工智能、信号处理、模式识别、统计学等学科。常见的方法主要分为两大类,分别是基于数学模型的方法和基于人工智能的方法,基于数学模型的方法是目前最广泛应用的一种故障检测方法。这种方法是以前监测到的信号为基础,通过信号处理分析,提取其特征信息,然后对比正常条件下的特征,从而判断分析设备是否故障,具体诊断原理图如图 1 所示。

[0004] 对于单一信号的检测分析比较简单,例如:某简单系统输出信号为  $y(t)$ ,如图 2 所示,在实际正常工况下,输出信号  $y(t)$  幅值在区间  $[\min(y(t)), \max(y(t))]$  内,如图 2 中红色虚线为幅度区间范围,这是系统正常工况下。理论上正常工况下,输出信号  $y(t)$  如图 2 中红色实线,比较实测输出信号与幅度区间范围,超出则为故障状态。实测输出信号如图 2 中蓝色实线所示。

[0005] 对于单一信号的检测容易建立其区间范围,若复杂系统,监测信号多元,又难以建立具体的包络模型,难以用此方法进行故障诊断。

### 发明内容

[0006] 本发明的目的在于提供一种使用方便、准确度高的复杂设备早期故障诊断方法,以解决上述背景技术中提出的问题。

[0007] 为实现上述目的,本发明提供如下技术方案:

[0008] 一种复杂设备早期故障诊断方法,具体步骤如下:

[0009] (1) 通过传感器提取采集信号;

[0010] (2) 对提取采集的信号进行小波变换去噪;

[0011] (3) 就机械特征和电路特征分别建立基于 BP 神经网络的故障诊断模型和基于 SVM 的故障诊断模型,进行故障诊断。

[0012] 作为本发明进一步的方案:所述基于 BP 神经网络的故障诊断模型进行故障诊断的方法,具体步骤如下:

- [0013] (1) 所述传感器连接在机械设备上提取采集信号；
- [0014] (2) 将提取采集的信号进行小波变换去噪处理后分别进行原始数据诊断和样本数据训练,再进入 BP 神经网络分别进行预处理和特征选择 / 提取；
- [0015] (3) 原始数据经预处理和特征选择 / 提取后再经过 BP 神经网络诊断得到诊断结果,样本数据经过预处理和特征选择 / 提取后进行学习训练；
- [0016] (4) 对于得到的诊断结果进行诊断决策,再分别进行定期维修、视情维修和事后维修。
- [0017] 作为本发明再进一步的方案:所述基于 SVM 的故障诊断模型中核函数为多项式核函数、径向基核函数 RBF 或 Sigmoid 核函数。
- [0018] 与现有技术相比,本发明的有益效果是：
- [0019] 本发明将复杂设备的故障诊断分为机械特征的故障诊断和电路特征的故障诊断,就机械特征和电路特征分别建立故障诊断模型,机械易试验,可获取样本多,运用 BP 神经网络收敛快,准确度较高;而电路样本数据少,运用 SVM 的小样本优势,从而实现复杂设备等复杂系统的故障诊断。

## 附图说明

- [0020] 图 1 为基于数学模型的方法具体诊断原理图。
- [0021] 图 2 为简单系统单一信号的检测分析示意图。
- [0022] 图 3 为本发明中故障诊断方法示意图。
- [0023] 图 4 为本发明中基于 BP 神经网络的故障诊断模型进行故障诊断的方法示意图。
- [0024] 图 5 为本发明中 BP 神经网络的拓扑结构图。
- [0025] 图 6 为本发明中 BP 神经网络的学习训练原理图。
- [0026] 图 7 为本发明中机械设备振动信号去噪提取后的信号波形图。
- [0027] 图 8 为本发明中基于 SVM 的故障诊断模型输入空间到高维特征空间的非线性映射图。
- [0028] 图 9 为本发明中基于 SVM 的故障诊断模型进行故障诊断的方法示意图。

## 具体实施方式

- [0029] 下面结合具体实施方式对本专利的技术方案作进一步详细地说明。
- [0030] 请参阅图 3,一种复杂设备早期故障诊断方法,具体步骤如下：
- [0031] (1) 通过传感器提取采集信号；
- [0032] (2) 对提取采集的信号进行小波变换去噪；
- [0033] (3) 就机械特征和电路特征分别建立基于 BP 神经网络的故障诊断模型和基于 SVM 的故障诊断模型,进行故障诊断。
- [0034] 请参阅图 4,所述基于 BP 神经网络的故障诊断模型进行故障诊断的方法,具体步骤如下：
- [0035] (1) 所述传感器连接在机械设备上提取采集信号；
- [0036] (2) 将提取采集的信号进行小波变换去噪处理后分别进行原始数据诊断和样本数据训练,再进入 BP 神经网络分别进行预处理和特征选择 / 提取；

[0037] (3) 原始数据经预处理和特征选择 / 提取后再经过 BP 神经网络诊断得到诊断结果, 样本数据经过预处理和特征选择 / 提取后进行学习训练;

[0038] (4) 对于得到的诊断结果进行诊断决策, 再分别进行定期维修、视情维修和事后维修。

[0039] 请参阅图 5, 所述 BP 神经网络包括输入层、中间层和输出层, 所述学习训练中的学习算法为有监督学习算法, 根据给出正确的输入和输出对 BP 神经网络进行调整, 让 BP 神经网络能做出正确的反应。学习训练样本表示为:  $(p_i, d_i)$ ,  $i = 1, 2, \dots, n$ , 其中,  $p_i$  为样本输入数据,  $d_i$  为样本输出数据, 通过学习调整各神经元的参数, 让 BP 神经网络产生期望的结果, BP 神经网络模型学习训练后, 再输入样本  $p_i$ , BP 神经网络的输出尽可能与  $d_i$  接近。

[0040] 请参阅图 6, BP 神经网络的学习分为两个阶段: 输入已经确定的学习样本, 设置 BP 神经网络的结构, 计算前一次迭代得到的权值和阈值, 从第一层向后计算, 求解各神经元的输出; 修改权值和阈值, 根据总误差影响梯度, 从最后一层向前, 分别计算修改各权值和阈值。两个阶段反复交替, 根据误差修改层与层之间的权值和阈值, 直到收敛后误差满足要求。

[0041] 以柴油发电机中的发动机为例说明机械设备旋转系统基于 BP 神经网络的故障诊断模型的构建, 请参阅图 6, 对柴油发电机中的发动机的振动信号去噪提取后的输出信号  $y(t)$  进行三层小波分解, 第三层的分解系数向量从低到高分别为  $[y_{30}, y_{31}, y_{32}, y_{33}, y_{34}, y_{35}, y_{36}, y_{37}]$  则总的信号  $y$ :

[0042]  $y = S_{30} + S_{31} + S_{32} + S_{33} + S_{34} + S_{35} + S_{36} + S_{37}$  公式 1

[0043] 其中,  $S_{30}$  表示节点  $y_{30}$  的重构恢复信号,  $S_{31}$  表示节点  $y_{31}$  的重构恢复信号,  $S_{32}$  表示节点  $y_{32}$  的重构恢复信号,  $S_{33}$  表示节点  $y_{33}$  的重构恢复信号,  $S_{34}$  表示节点  $y_{34}$  的重构恢复信号,  $S_{35}$  表示节点  $y_{35}$  的重构恢复信号,  $S_{36}$  表示节点  $y_{36}$  的重构恢复信号,  $S_{37}$  表示节点  $y_{37}$  的重构恢复信号。

[0044] 假设输出信号  $y(t)$  中的最低频率为 0, 最高频率为 1, 这样分为八个频率范围, 如表 1 所示:

[0045] 表 1 小波分解后信号的频率范围

[0046]

| 信号成分     | 频率区间          | 信号成分     | 频率区间          |
|----------|---------------|----------|---------------|
| $S_{30}$ | 0 ~ 0.125     | $S_{34}$ | 0.500 ~ 0.625 |
| $S_{31}$ | 0.125 ~ 0.250 | $S_{35}$ | 0.625 ~ 0.750 |
| $S_{32}$ | 0.250 ~ 0.375 | $S_{36}$ | 0.750 ~ 0.875 |
| $S_{33}$ | 0.375 ~ 0.500 | $S_{37}$ | 0.875 ~ 1     |

[0047] 输入信号的确定: 输入信号包括频带信号能量和时域陡峭度。

[0048] 将输出信号  $y(t)$  小波分解到八个频带, 计算各频带信号能量:

[0049]  $E_{3j} = \int_{T_s} |S_{3j}(t)|^2 dt = \sum_{k=1}^N |y_{jk}|^2$  公式 2

[0050] 其中,  $E_{3j}$  为频带  $S_{3j}$  对应的能力,  $T_s$  为输出信号  $y(t)$  的分析周期,  $j = 0, 1, \dots, 7, k = 1, 2, \dots, N$ ,  $N$  为样本数量,  $y_{jk}$  为  $S_{3j}$  信号第  $k$  个离散点幅值。

[0051] 为了提高 BP 神经网络的准确率, 将各频带能量作归一化处理:

$$[0052] \quad \bar{E}_{3j} = \frac{E_{3j}}{\sum_{j=0}^7 E_{3j}} \quad \text{公式 3}$$

[0053] 因而得到各频带信号能量的八个特征向量:

$$[0054] \quad T = [\bar{E}_{30}, \bar{E}_{31}, \bar{E}_{32}, \bar{E}_{33}, \bar{E}_{34}, \bar{E}_{35}, \bar{E}_{36}, \bar{E}_{37}] \quad \text{公式 4}$$

[0055] 所述机械设备旋转系统的振动信号的概率分布接近于正太分布, 而时域陡峭度是定量的描述实测信号偏离正太分布的程度, 时域陡峭度计算方法如下:

$$[0056] \quad g_3 = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^3 \quad \text{公式 5}$$

$$[0057] \quad g_4 = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^4 \quad \text{公式 6}$$

[0058] 采用最值归一化处理:

$$[0059] \quad \hat{g}_i = \frac{g_i - g_{i\min}}{g_{i\max} - g_{i\min}} \quad \text{公式 7}$$

[0060] 其中,  $\hat{g}_i$  为归一化之后的数据,  $g_i$  为归一化之前的数据,  $g_{i\min}$ 、 $g_{i\max}$  分别为归一化之前数据的最小值和最大值。

[0061] 因此, BP 神经网络输入参数  $P$  的变量为 10 个:

$$[0062] \quad P = [\bar{E}_{30}, \bar{E}_{31}, \bar{E}_{32}, \bar{E}_{33}, \bar{E}_{34}, \bar{E}_{35}, \bar{E}_{36}, \bar{E}_{37}, \hat{g}_3, \hat{g}_4] \quad \text{公式 8}$$

[0063] 输出参数的确定:

[0064] 对于发动机故障诊断, 所述振动故障包括数十种类型, 其中有几种典型故障, 其发生率约占总数的 95 以上, 所述典型故障包括转子不平衡、转子碰摩、转子不对中和轴承松动等。

[0065] 因此以这四种典型故障作为 BP 神经网络故障诊断模型输出参数, 表示为

$$[0066] \quad D = [d_1, d_2, d_3, d_4], 0 < d_i \leq 1 \quad \text{公式 9}$$

[0067] 其理想输出状态及含义如表 2 所示:

[0068] 表 3.2 输出状态及定义

[0069]

| 故障类型  | $d_1$ | $d_2$ | $d_3$ | $d_4$ |
|-------|-------|-------|-------|-------|
| 转子不平衡 | 1     | 0     | 0     | 0     |
| 转子碰摩  | 0     | 1     | 0     | 0     |
| 转子不对中 | 0     | 0     | 1     | 0     |

|      |   |   |   |   |
|------|---|---|---|---|
| 轴承松动 | 0 | 0 | 0 | 1 |
|------|---|---|---|---|

[0070] 因此, BP 神经网络故障诊断模型中, 输入层中的输入节点为十个, 输入节点包括八个频带能量信号和两个时域陡峭度, 输出层中的输出节点为四个, 根据 2M+1 的原则, 中间层的隐层节点为二十一个。

[0071] 所述 BP 神经网络模型具有良好的非线性能力, 对于实际非线性系统, 其结构简单, 性能良好。故障诊断的关键是从故障特征空间实现到故障空间的一种映射, 这样达到故障诊断的目的。BP 神经网络具有适应能力, 网络不仅能自适应的学习, 还可以调整网络大小, 另外, BP 神经网络具有一定的容错性, 表现在对输入模式信息的不完备, 或者对特征的缺损不太敏感, 而对于复杂设备中机械特征明显, 容易通过实验获取大量的故障样本, 保证了 BP 神经网络的可信度。因而, BP 神经网络实现复杂系统中复杂设备的故障诊断可行有效的。

[0072] 请参阅图 8-9, 所述基于 SVM 的故障诊断模型中经过小波去噪后的信号 N 维输入, 输出特征样本  $(x_i, y_i)$ , 通过选择非线性变换  $\theta(\cdot)$ , 实现从原空间向高维特征空间的映射 F, 其中  $x_i \in \mathbb{R}^n$  作为输入向量,  $y_i \in [-1, 1]$  作为输出故障类别,  $i = 1, 2, \dots, N$ , N 表示训练样本的数量。

[0073] 构建最优线性分类函数:

[0074]  $f(x) = \text{sign}[(w \cdot \theta(x) + b)]$  公式 10

[0075] 其中, w 为权重向量; b 为偏差或为分类阈值。

[0076] 为满足结构风险最小化, 需寻找 w 和 b 使公式 11 成立:

[0077]  $\min R = \frac{1}{2} w^T w + C \cdot R_p$  公式 11

[0078] 其中,  $w^T w$  为控制模型的复杂度, C 为预先确定常数, 实现对输出误差的样本控制惩罚程度;  $R_p$  为误差控制函数。

[0079] 所述误差控制函数为  $R_p$  误差  $\xi$  的二范数, 因此故障诊断模型可以优化为:

[0080]  $\min Q(w, b, \xi) = \frac{1}{2} w^T w + \frac{1}{2} C \cdot \sum_{i=1}^N \xi_i^2$  公式 12

[0081]  $\text{st. } y_i [w^T \cdot \theta(x_i) + b] = 1 - \xi$

[0082] 由于权重向量可能是无限维, 将公式 12 转化为如下方程组:

[0083]  $\begin{bmatrix} 0 & 1^T \\ 1 & K + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix}$  公式 13

[0084] 其中,  $1 = [1, 1, \dots, 1]^T$ ,  $Y = [y_1, y_2, \dots, y_N]^T$ ,  $a = [a_1, a_2, \dots, a_N]^T$ , I 为单位矩阵,  $K = \theta(x_i)^T \theta(x_j)$  是核函数。

[0085] 所述核函数为多项式核函数、径向基核函数 RBF 或 Sigmoid 核函数。具体函数形式如下: 多项式核函数  $K(x, x') = (x \cdot x' + 1)^d$ , 其中, d 为核函数的阶数。径向基核函数 RBF:  $K(x, x') = \exp(-\gamma \|x - x'\|^2)$ , 其中  $\gamma > 0$ ,  $\gamma$  为控制半径的系数。Sigmoid 核函数:  $K(x, x') = \tanh(vx^T x_i + \alpha)$ 。

[0086] 当核函数为径向基核函数时, 采用最小二乘法得到 b 和 a 的值, 最后可以得到经过

小波去噪后的故障分类函数：

[0087] 
$$f(x) = \text{sgn}[\sum_{i=1}^N a_i K(x, x_i) + b]$$
 公式 14

[0088] 所述基于 SVM 的故障诊断模型在训练时,输入训练样本  $(x_1, y_1), \dots, (x_N, y_N)$ , 其中,  $x_i \in X = R^n, Y = \{1, 2, \dots, m\}, i = 1, 2, \dots, N, N$  为训练样本数,  $n$  为输入变量数,  $m$  为故障类别数;确定核函数的类型;运用二次规划方法来求目标函数式最优解,并得到最优的  $a$ ;利用样本库中的一个支持向量机  $X$ ,代入公式 13,得到偏差值  $b$ 。

[0089] SVM 的分类方法包括一对一和一对多的方法,一对一方法训练速度比一对多快得多,而且全局优化能力强,在训练效果上,一对多方法需要将其中某个类的样本从其他样本类中区别开来,分类超平面相比一对一方法更加复杂,且更容易发生过量匹配问题。因此,一对一方法更加适合于工程应用。

[0090] 本发明将复杂设备的故障诊断分为机械特征的故障诊断和电路特征的故障诊断,就机械特征和电路特征分别建立故障诊断模型,机械易试验,可获取样本多,运用 BP 神经网络收敛快,准确度较高;而电路样本数据少,运用 SVM 的小样本优势,从而实现复杂设备等复杂系统的故障诊断。

[0091] 上面对本专利的较佳实施方式作了详细说明,但是本专利并不限于上述实施方式,在本领域的普通技术人员所具备的知识范围内,还可以在不脱离本专利宗旨的前提下作出各种变化。




图 1




图 2




图 3




图 4




图 5




图 6




图 7




图 8




图 9