



(12)发明专利申请

(10)申请公布号 CN 109344518 A

(43)申请公布日 2019.02.15

(21)申请号 201811193462.4

(22)申请日 2018.10.14

(71)申请人 毛述春

地址 401121 重庆市渝北区红叶路8号19幢
6-1

(72)发明人 毛述春

(74)专利代理机构 重庆市诺兴专利代理事务所
(普通合伙) 50239

代理人 刘兴顺

(51) Int. Cl.

G06F 17/50(2006.01)

G06N 3/06(2006.01)

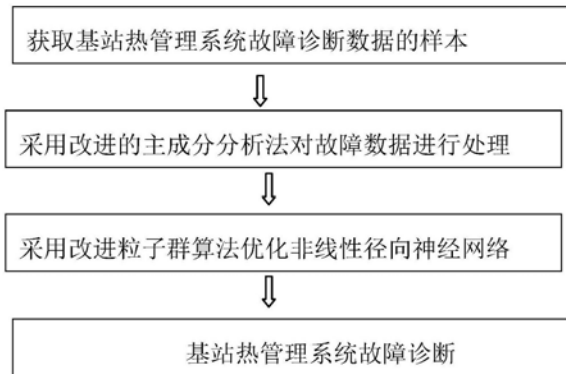
权利要求书3页 说明书7页 附图1页

(54)发明名称

一种基站热管理系统的故障诊断方法

(57)摘要

本发明请求保护一种基站热管理系统故障诊断方法,其包括以下步骤:选定基站热管理系统的可测输出量,分别采集正常情况和故障情况下的样本数据;采用改进的主成分分析法对步骤1所述采集到的基站热管理系统的正常情况和故障情况的样本数据进行特征提取,筛选出重要的指标,改进的主成分分析法得到降维后的样本数据,将降维后的样本数据分为训练集和测试集;建立基于非线性径向神经网络故障诊断模型,采用改进的粒子群优化算法优化神经网络故障诊断模型的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} ,将采集的基站热管理系统的输入数据输入诊断模型,将诊断模型与基准模型间各测点压力值的相似性进行评估来计算误差,得到模型准确度量化指标,判断故障源。



1. 一种基站热管理系统的故障诊断方法,所述基站热管理系统包括设置在基站内的空调器、温控装置以及设备柜,所述空调器、设备柜之间通过冷通道及热通道连通,所述冷通道及所述热通道具有与外界连通的风口;其中,所述温控装置包括:用于检测所述设备柜进风温度的第一温度传感器,设置在所述设备柜的进风口的第一风机;还包括控制装置,用于在所述第一温度传感器检测的所述设备柜的进风温度小于设定的第一温度时,根据设定的温度与第一风机转速的对应关系控制所述第一风机的转速;还包括:检测基站温度的第二温度传感器;主控制装置,用于在所述第二温度传感器检测基站的温度小于设定的第二温度时,控制所述空调停止工作,并控制所述温度控制装置开始工作;其中,所述第二温度大于所述第一温度,其特征在于,包括以下步骤:

步骤101:选定基站热管理系统的可测输出量,包括采集基站内的空调器、温控装置以及设备柜的温度数据,以及冷通道、热通道的数据,分别采集正常情况和故障情况下的样本数据;

步骤102:采用改进的主成分分析法对步骤1所述采集到的基站热管理系统的正常情况和故障情况的样本数据进行特征提取,改进的主成分分析法改进点主要在于:首先进行相关性分析,将空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数据设置成一次筛选数据,对于控制装置、主控制装置的控制参数数据不进行筛选,由参数模型进行比对;首先进行温度数据筛选得出一次指标,并设置重要度 w 对一次指标的重要性进行排序,其中重要度升序排序为:空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数据,进行第一次筛选数据并进行若干次计算得到加成后的指标,再次降序排序得出排序后的二次指标,并将排序低于设定值的指标进行一次删除;再进行主成分分析,包括:将一次删除数据按行排列组成矩阵 X ;对 X 进行数据标准化,使其均值变为零求 X 的协方差矩阵 C ;将特征向量按特征值由大到小排列,取前 k 个按行组成矩阵 P ;通过计算 $Y=PX$,得到降维后数据 Y ;用下式计算每个特征根的贡献率根据特征根及其特征向量解释主成分物理意义即指标的因子载荷;再第二次删除因子载荷小于设定值的指标,保证筛选出重要的指标,改进的主成分分析法得到降维后的样本数据,将降维后的样本数据分为训练集和测试集;

步骤103:建立基于非线性径向神经网络故障诊断模型,采用改进的粒子群优化算法优化神经网络故障诊断模型的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} ,将步骤102的训练集数据用于RBF神经网络故障诊断模型的训练,并得到优化后的基于非线性径向神经网络故障诊断模型,采集基站内的空调器、温控装置以及设备柜的数据;将基站内的空调器、温控装置以及设备柜的数据输入优化后的基于非线性径向神经网络故障诊断模型,将优化后的基于非线性径向神经网络故障诊断模型与基准模型进行比对进行评估来计算误差,得到模型准确度量化指标,判断故障源。

2. 根据权利要求1所述的一种基站热管理系统的故障诊断方法,其特征在于,所述采用主成分分析法对步骤1所述样本数据进行特征提取,得到降维后的样本数据,将降维后的样本数据分为训练集和测试集,具体包括:

故障样本数据为 $X(X \in R^{n \times m})$, $R^{n \times m}$ 为故障样本集, n 为变量个数, m 为样本个数;采用均值标准差标准化方法处理故障样本数据;建立标准化变量的协方差矩阵,求解协方差矩阵的特征值特征向量,协方差矩阵求解为:

$$C = \frac{1}{m} \sum_{i=1}^n (x^{(i)})(x^{(i)})^T \quad (1)$$

其中 $x^{(i)}$ 为一个样本数据向量， $(x^{(i)})^T$ 表示 $x^{(i)}$ 的转置向量，协方差矩阵的特征值为 A_i ($i = 1, 2, \dots, n$)，每个特征值对应一个特征向量；

计算前 k 个主成分对总均方差的贡献率，均方差贡献率为：

$$d_k = \frac{\lambda_k}{\sum_{j=1}^n \lambda_j} \quad (2),$$

式中， λ_k 表示第 k 个主成分的均方差，取累计均方差贡献率大于 $d_{\text{设}}$ ，得到的 k 值为主成分个数；

主成分值方程为：

$$Z = U^T x \quad (3)$$

其中 Z 为主成分值， U ($U \in R^{n \times k}$) 为由前 k 个特征矩阵构建的特征向量， x ($x \in R^{n \times 1}$) 为各样本向量。

3. 根据权利要求1所述的一种基站热管理系统的故障诊断方法，其特征在于，所述基于非线性径向神经网络的输入为：

$$X1 = [x_1, x_2, \dots, x_n]^T \quad (4),$$

其中， n 为输入节点个数， $X1$ 为上述经过归一化和降维处理的高压零部件的可测输出量的特征参数值；

RBF神经网络的输出为 y_m ；隐含层的激励函数取高斯基函数，即：

$$R_j(X - c_j) = \exp(-\|X - c_j\| / 2\sigma_j^2), j = 1, 2, \dots, p \quad (5)$$

其中， c_j 为基函数的中心， σ_j 为神经元高斯基函数的方差， p 为隐含层的神经元数量；RBF神经网络的输入和输出之间的关系表达式为：

$$y_i = \sum_{j=1}^p w_{ij} \exp(-\|x - c_j\|^2 / 2\sigma_j^2), i = 1, 2, \dots, m \quad (6)$$

其中， y_i 为第 i 个神经元的输出值； w_{ij} 为隐含层第 j 个神经元到输出层第 i 个神经元的连接权值； m 为输出层神经元个数。

4. 根据权利要求1所述的一种基站热管理系统的故障诊断方法，其特征在于，所述采用粒子群PSO算法优化RBF神经网络，将RBF神经网络的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} 作为粒子群算法中的粒子，根据粒子群的群体适应度方差决定是否更新粒子，粒子的速度和位置的更新公式为：

$$v_{ij}^{k+1} = w_p v_{ij}^k + c_1 r_1 (P_{ij}^k - b_{ij}^k) + c_2 r_2 (P_{gj}^k - b_{ij}^k) \quad (7)$$

$$b_{ij}^{k+1} = b_{ij}^k + v_{ij}^{k+1} \quad (8)$$

其中， v_{ij}^{k+1} 为粒子第 $k+1$ 次迭代的速度， k 代表当前为第 k 次迭代， w_p 为惯性权重， $j = 1, 2, \dots, s$ ， P_i 为个体最优解， b_{ij}^{k+1} 为第 $k+1$ 次迭代后的位置， P_g 为全局最优解， c_1 、 c_2 、 r_1 、 r_2 为随机数，分别取值为(0~2)、(0~2)、(0~1)、(0~1)，因子 c_1 、 c_2 代表将粒子推向 P_i 和 P_g 的权重；以上述RBF神经网络模型均方根误差最小为适应度函数：

$$f = \sqrt{\frac{1}{m} \sum_{i=1}^m (y'_i - y_i)^2} \quad (9)$$

其中, y'_i 为等效模型输出数据, y_i 为样本值;

粒子群的适应度方差为:

$$\sigma_p^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{f_i - f_{avg}}{f} \right)^2 \quad (10)$$

式中, σ_p^2 为粒子群的适应度方差, f_i 为第 i 个粒子的适应度, f_{avg} 为粒子的平均适应度, f 为一常数;

每一次更新位置后, 按照概率对粒子进行变异操作, 其概率函数为:

$$p = \begin{cases} \lambda & \sigma_p^2 < \mu \text{ 且 } |P_g - f_m| > \delta \\ 0 & \text{其他} \end{cases} \quad (11)$$

λ ($\lambda \in [0, 1]$) 为常数, μ 为远小于 σ_p^2 最大值的常数, δ 为收敛精度, P_g 为全局最优解, f_m 为理论最优值; 满足变异操作概率条件时, 产生随机数 $r \in [0, 1]$, 若 $r < p$, 对粒子 i 个体极值位置进行变异操作:

$$b_i = b_i \times (1+d) \quad (12)$$

d 为 $[0, 1]$ 之间符合标准正态分布的随机数;

得到降维后的样本数据, 将降维后的样本数据分为训练集和测试集。

一种基站热管理系统的故障诊断方法

技术领域

[0001] 本发明属于通信基站应用领域,尤其涉及一种基站热管理系统的故障诊断方法。

背景技术

[0002] 传统室内型基站中通信主设备与电源设备的发热量都较大,一般是通过配置空调器来降温。采用这种空调器降温方式,有以下两点缺陷:第一点是能耗较大。在室内型基站机房中,主设备、电池与电源设备分散安装在不同位置空间,这就需要所配的空调器需要对整个机房室内空间进行制冷降温。一般使用2匹以上功率的空调器,而且空调器一年四季被设定在某个温度下持续工作,例如25摄氏度或者更低的温度;在冬天或者晚上的时候,环境温度往往要低于这个设定温度值,这个时候基站内的设备温度不会偏高,空调器是可以不需要运行的,这样就额外的能量消耗会造成大量的电能损失。第二点是维护成本高。由于空调器常年持续工作,空调器滤网与压缩机长期处在工作状态,因此相关的制冷设备容易发生损坏或出现故障,需要增加维护次数,频繁地维护导致维护成本大大增加。在利用神经网络故障诊断模型对基站热管理系统进行故障诊断时,学者们多采用BP神经网络。但BP神经网络容易陷入局部最优,且收敛速度慢,可采用RBF神经网络用于基站热管理系统故障诊断解决这一问题。同时采用改进的粒子群算法优化RBF神经网络模型的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} ,得到神经网络故障诊断模型的最优参数。

发明内容

[0003] 本发明旨在解决以上现有技术的问题。提出了一种可以及时检测到热管理系统故障并直接确定故障位置的基站热管理系统的故障诊断方法。本发明的技术方案如下:

[0004] 一种基站热管理系统的故障诊断方法,所述基站热管理系统包括设置在基站内的空调器、温控装置及设备柜,所述空调器、设备柜之间通过冷通道及热通道连通,所述冷通道及所述热通道具有与外界连通的风口;其中,所述温控装置包括:用于检测所述设备柜进风温度的第一温度传感器,设置在所述设备柜的进风口的第一风机;还包括控制装置,用于在所述第一温度传感器检测的所述设备柜的进风温度小于设定的第一温度时,根据设定的温度与第一风机转速的对应关系控制所述第一风机的转速;还包括:检测基站温度的第二温度传感器;主控制装置,用于在所述第二温度传感器检测基站的温度小于设定的第二温度时,控制所述空调停止工作,并控制所述温度控制装置开始工作;其中,所述第二温度大于所述第一温度,包括以下步骤:

[0005] 步骤101:选定基站热管理系统的可测输出量,包括采集基站内的空调器、温控装置及设备柜的温度数据,以及冷通道、热通道的数据,分别采集正常情况和故障情况下的样本数据;

[0006] 步骤102:采用改进的主成分分析法对步骤1所述采集到的基站热管理系统的正常情况和故障情况的样本数据进行特征提取,改进的主成分分析法改进点主要在于:首先进行相关性分析,将空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数

据设置成一次筛选数据,对于控制装置、主控制装置的控制参数数据不进行筛选,由参数模型进行比对;首先进行温度数据筛选得出一次指标,并设置重要度 w 对一次指标的重要性进行排序,其中重要度升序排序为:空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数据,进行第一次筛选数据并进行若干次计算得到加成后的指标,再次降序排序得出排序后的二次指标,并将排序低于设定值的指标进行一次删除;再进行主成分分析,包括:将一次删除数据按行排列组成矩阵 X ;对 X 进行数据标准化,使其均值变为零求 X 的协方差矩阵 C ;将特征向量按特征值由大到小排列,取前 k 个按行组成矩阵 P ;通过计算 $Y=PX$,得到降维后数据 Y ;用下式计算每个特征根的贡献率根据特征根及其特征向量解释主成分物理意义即指标的因子载荷;再第二次删除因子载荷小于设定值的指标,保证筛选出重要的指标,改进的主成分分析法得到降维后的样本数据,将降维后的样本数据分为训练集和测试集;

[0007] 步骤103:建立基于非线性径向神经网络故障诊断模型,采用改进的粒子群优化算法优化神经网络故障诊断模型的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} ,将步骤102的训练集数据用于RBF神经网络故障诊断模型的训练,并得到优化后的基于非线性径向神经网络故障诊断模型,采集基站内的空调器、温控装置以及设备柜的数据;将基站内的空调器、温控装置以及设备柜的数据输入优化后的基于非线性径向神经网络故障诊断模型,将优化后的基于非线性径向神经网络故障诊断模型与基准模型进行比对进行评估来计算误差,得到模型准确度量指标,判断故障源。

[0008] 进一步的,所述采用主成分分析法对步骤1所述样本数据进行特征提取,得到降维后的样本数据,将降维后的样本数据分为训练集和测试集,具体包括:

[0009] 故障样本数据为 $X (X \in R^{n \times m})$, $R^{n \times m}$ 为故障样本集, n 为变量个数, m 为样本个数;采用均值标准差标准化方法处理故障样本数据;建立标准化变量的协方差矩阵,求解协方差矩阵的特征值特征向量,协方差矩阵求解为:

$$[0010] \quad C = \frac{1}{m} \sum_{i=1}^n (x^{(i)})(x^{(i)})^T \quad (1)$$

[0011] 其中 $x^{(i)}$ 为一个样本数据向量, $(x^{(i)})^T$ 表示 $x^{(i)}$ 的转置向量,协方差矩阵的特征值为 $A_i (i=1, 2, \dots, n)$,每个特征值对应一个特征向量;

[0012] 计算前 k 个主成分对总均方差的贡献率,均方差贡献率为:

$$[0013] \quad d_k = \frac{\lambda_k}{\sum_{j=1}^n \lambda_j} \quad (2),$$

[0014] 式中, λ_k 表示第 k 个主成分的均方差,取累计均方差贡献率大于 $d_{\text{设}}$,得到的 k 值为主成分个数;

[0015] 主成分值方程为:

$$[0016] \quad Z = U^T x \quad (3)$$

[0017] 其中 Z 为主成分值, $U (U \in R^{n \times k})$ 为由前 k 个特征矩阵构建的特征向量, $x (x \in R^{n \times 1})$ 为各样本向量。

[0018] 进一步的,所述基于非线性径向神经网络的输入为: $X1 = [x_1, x_2, \dots, x_n]^T (4)$,其中, n 为输入节点个数, $X1$ 为上述经过归一化和降维处理的高压零部件的可测输出量的特征

参数值;

[0019] RBF神经网络的输出为 y_m ;隐含层的激励函数取高斯基函数,即:

$$[0020] \quad R_j(X - c_j) = \exp(-\|X - c_j\| / 2\sigma_j^2), j = 1, 2, \dots, p \quad (5)$$

[0021] 其中, c_j 为基函数的中心, σ_j 为神经元高斯基函数的方差, p 为隐含层的神经元数量;RBF神经网络的输入和输出之间的关系表达式为:

$$[0022] \quad y_i = \sum_{j=1}^p w_{ij} \exp(-\|x - c_j\|^2 / 2\sigma_j^2), i = 1, 2, \dots, m \quad (6)$$

[0023] 其中, y_i 为第 i 个神经元的输出值; w_{ij} 为隐含层第 j 个神经元到输出层第 i 个神经元的连接权值; m 为输出层神经元个数。

[0024] 进一步的,所述采用粒子群PSO算法优化RBF神经网络,将RBF神经网络的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} 作为粒子群算法中的粒子,根据粒子群的群体适应度方差决定是否更新粒子,粒子的速度和位置的更新公式为:

$$[0025] \quad v_{ij}^{k+1} = w_p v_{ij}^k + c_1 r_1 (P_{ij}^k - b_{ij}^k) + c_2 r_2 (P_{gj}^k - b_{ij}^k) \quad (7)$$

$$[0026] \quad b_{ij}^{k+1} = b_{ij}^k + v_{ij}^{k+1} \quad (8)$$

[0027] 其中, v_{ij}^{k+1} 为粒子第 $k+1$ 次迭代的速度, k 代表当前为第 k 次迭代, w_p 为惯性权重, $j = 1, 2, \dots, s$, P_i 为个体最优解, b_{ij}^{k+1} 为第 $k+1$ 次迭代后的位置, P_g 为全局最优解, c_1 、 c_2 、 r_1 、 r_2 为随机数,分别取值为(0~2)、(0~2)、(0~1)、(0~1),因子 c_1 、 c_2 代表将粒子推向 P_i 和 P_g 的权重;以上述RBF神经网络模型均方根误差最小为适应度函数:

$$[0028] \quad f = \sqrt{\frac{1}{m} \sum_{i=1}^m (y'_i - y_i)^2} \quad (9)$$

[0029] 其中, y'_i 为等效模型输出数据, y_i 为样本值;

[0030] 粒子群的适应度方差为:

$$[0031] \quad \sigma_p^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{f_i - f_{avg}}{f} \right)^2 \quad (10)$$

[0032] 式中, σ_p^2 为粒子群的适应度方差, f_i 为第 i 个粒子的适应度, f_{avg} 为粒子的平均适应度, f 为一常数;

[0033] 每一次更新位置后,按照概率对粒子进行变异操作,其概率函数为:

$$[0034] \quad p = \begin{cases} \lambda & \sigma_p^2 < \mu \text{ 且 } |P_g - f_m| > \delta \\ 0 & \text{其他} \end{cases} \quad (11)$$

[0035] λ ($\lambda \in [0, 1]$) 为常数, μ 为远小于 σ_p^2 最大值的常数, δ 为收敛精度, P_g 为全局最优解, f_m 为理论最优值;满足变异操作概率条件时,产生随机数 $r \in [0, 1]$,若 $r < p$,对粒子 i 个体极值位置进行变异操作:

$$[0036] \quad b_i = b_i \times (1+d) \quad (12)$$

[0037] d 为 $[0, 1]$ 之间符合标准正态分布的随机数;

[0038] 得到降维后的样本数据,将降维后的样本数据分为训练集和测试集。

[0039] 本发明的优点及有益效果如下：

[0040] 本发明通过采用改进的主成分分析法对步骤1所述采集到的基站热管理系统的正常情况和故障情况的样本数据进行特征提取,改进的主成分分析法改进点主要在于:首先进行相关性分析筛选得出一次指标,并设置重要度 w 对一次指标的重要性进行排序,并进行若干次计算得到加成后的指标,再次降序排序得出排序后的二次指标,并将排序低于设定值的指标进行一次删除;再进行主成分分析,得到指标的因子载荷;再第二次删除因子载荷小于设定值的指标,保证筛选出重要的指标,采用设置重要度的方法可以实现前期即对不重要的指标进行排除,改进的主成分分析法得到降维后的样本数据。采用粒子群算法优化RBF神经网络的基函数中心、方差和连接权值,提高了网络模型的收敛速度。对粒子群算法中粒子的个体极值位置进行变异操作,解决粒子群算法容易陷入局部极值问题。将采集站内的空调器、温控装置以及设备柜的数据输入优化后的基于非线性径向神经网络故障诊断模型,将优化后的基于非线性径向神经网络故障诊断模型与基准模型进行比对进行评估来计算误差,得到模型准确度量指标,能够直接得到各执行件的故障状态,直接定位高压绝缘系统的故障部件。

附图说明

[0041] 图1是本发明提供优选实施例一种基站热管理系统的故障诊断方法流程示意图;

[0042] 图2是改进的粒子群优化算法示意图。

具体实施方式

[0043] 下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、详细地描述。所描述的实施例仅仅是本发明的一部分实施例。

[0044] 本发明解决上述技术问题的技术方案是：

[0045] 如图1所示,一种基站热管理系统的故障诊断方法,所述基站热管理系统包括设置在基站内的空调器、温控装置以及设备柜,所述空调器、设备柜之间通过冷通道及热通道连通,所述冷通道及所述热通道具有与外界连通的风口;其中,所述温控装置包括:用于检测所述设备柜进风温度的第一温度传感器,设置在所述设备柜的进风口的第一风机;还包括控制装置,用于在所述第一温度传感器检测的所述设备柜的进风温度小于设定的第一温度时,根据设定的温度与第一风机转速的对应关系控制所述第一风机的转速;还包括:检测基站温度的第二温度传感器;主控制装置,用于在所述第二温度传感器检测基站的温度小于设定的第二温度时,控制所述空调停止工作,并控制所述温度控制装置开始工作;其中,所述第二温度大于所述第一温度,其包括以下步骤:

[0046] 步骤101:选定基站热管理系统的可测输出量,包括采集基站内的空调器、温控装置以及设备柜的温度数据,以及冷通道、热通道的数据,分别采集正常情况和故障情况下的样本数据;

[0047] 步骤102:采用改进的主成分分析法对步骤1所述采集到的基站热管理系统的正常情况和故障情况的样本数据进行特征提取,改进的主成分分析法改进点主要在于:首先进行相关性分析,将空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数据设置成一次筛选数据,对于控制装置、主控制装置的控制参数数据不进行筛选,由参数模

型进行比对;首先进行温度数据筛选得出一次指标,并设置重要度 w 对一次指标的重要性进行排序,其中重要度升序排序为:空调器、设备柜的温度数据、第一温度传感器、第二温度传感器的温度数据,进行第一次筛选数据并进行若干次计算得到加成后的指标,再次降序排序得出排序后的二次指标,并将排序低于设定值的指标进行一次删除;再进行主成分分析,包括:将一次删除数据按行排列组成矩阵 X ;对 X 进行数据标准化,使其均值变为零求 X 的协方差矩阵 C ;将特征向量按特征值由大到小排列,取前 k 个按行组成矩阵 P ;通过计算 $Y=PX$,得到降维后数据 Y ;用下式计算每个特征根的贡献率根据特征根及其特征向量解释主成分物理意义即指标的因子载荷;再第二次删除因子载荷小于设定值的指标,保证筛选出重要的指标,改进的主成分分析法得到降维后的样本数据,将降维后的样本数据分为训练集和测试集;

[0048] 步骤103:建立基于非线性径向神经网络故障诊断模型,采用改进的粒子群优化算法优化神经网络故障诊断模型的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} ,将步骤102的训练集数据用于RBF神经网络故障诊断模型的训练,并得到优化后的基于非线性径向神经网络故障诊断模型,采集基站内的空调器、温控装置以及设备柜的数据;将基站内的空调器、温控装置以及设备柜的数据输入优化后的基于非线性径向神经网络故障诊断模型,将优化后的基于非线性径向神经网络故障诊断模型与基准模型进行比对进行评估来计算误差,得到模型准确度量化指标,判断故障源。

[0049] 优选的,所述采用主成分分析法对步骤1所述样本数据进行特征提取,得到降维后的样本数据,将降维后的样本数据分为训练集和测试集,具体包括:

[0050] 故障样本数据为 $X (X \in R^{n \times m})$, $R^{n \times m}$ 为故障样本集, n 为变量个数, m 为样本个数;采用均值标准差标准化方法处理故障样本数据;建立标准化变量的协方差矩阵,求解协方差矩阵的特征值特征向量,协方差矩阵求解为:

$$[0051] \quad C = \frac{1}{m} \sum_{i=1}^n (x^{(i)})(x^{(i)})^T \quad (1)$$

[0052] 其中 $x^{(i)}$ 为一个样本数据向量, $(x^{(i)})^T$ 表示 $x^{(i)}$ 的转置向量,协方差矩阵的特征值为 $A_i (i=1, 2, \dots, n)$,每个特征值对应一个特征向量;

[0053] 计算前 k 个主成分对总均方差的贡献率,均方差贡献率为:

$$[0054] \quad d_k = \frac{\lambda_k}{\sum_{j=1}^n \lambda_j} \quad (2),$$

[0055] 式中, λ_k 表示第 k 个主成分的均方差,取累计均方差贡献率大于 $d_{\text{设}}$,得到的 k 值为主成分个数;

[0056] 主成分值方程为:

$$[0057] \quad Z = U^T x \quad (3)$$

[0058] 其中 Z 为主成分值, $U (U \in R^{n \times k})$ 为由前 k 个特征矩阵构建的特征向量, $x (x \in R^{n \times 1})$ 为各样本向量。

[0059] 优选的,所述基于非线性径向神经网络的输入为: $X1 = [x_1, x_2, \dots, x_n]^T$ (4),其中, n 为输入节点个数, $X1$ 为上述经过归一化和降维处理的高压零部件的可测输出量的特征参数值;

[0060] RBF神经网络的输出为 y_m ;隐含层的激励函数取高斯基函数,即:

$$[0061] \quad R_j(X - c_j) = \exp(-\|X - c_j\| / 2\sigma_j^2), j = 1, 2, \dots, p \quad (5)$$

[0062] 其中, c_j 为基函数的中心, σ_j 为神经元高斯基函数的方差, p 为隐含层的神经元数量;RBF神经网络的输入和输出之间的关系表达式为:

$$[0063] \quad y_i = \sum_{j=1}^p w_{ij} \exp(-\|x - c_j\|^2 / 2\sigma_j^2), i = 1, 2, \dots, m \quad (6)$$

[0064] 其中, y_i 为第 i 个神经元的输出值; w_{ij} 为隐含层第 j 个神经元到输出层第 i 个神经元的连接权值; m 为输出层神经元个数。

[0065] 优选的,如图2所示,所述采用粒子群PSO算法优化RBF神经网络,将RBF神经网络的基函数中心位置 c_j 、方差 σ_j 和连接权值 w_{ij} 作为粒子群算法中的粒子,根据粒子群的群体适应度方差决定是否更新粒子,粒子的速度和位置的更新公式为:

$$[0066] \quad v_{ij}^{k+1} = w_p v_{ij}^k + c_1 r_1 (P_{ij}^k - b_{ij}^k) + c_2 r_2 (P_{gj}^k - b_{ij}^k) \quad (7)$$

$$[0067] \quad b_{ij}^{k+1} = b_{ij}^k + v_{ij}^{k+1} \quad (8)$$

[0068] 其中, v_{ij}^{k+1} 为粒子第 $k+1$ 次迭代的速度, k 代表当前为第 k 次迭代, w_p 为惯性权重, $j = 1, 2, \dots, s$, P_i 为个体最优解, b_{ij}^{k+1} 为第 $k+1$ 次迭代后的位置, P_g 为全局最优解, c_1 、 c_2 、 r_1 、 r_2 为随机数,分别取值为(0~2)、(0~2)、(0~1)、(0~1),因子 c_1 、 c_2 代表将粒子推向 P_i 和 P_g 的权重;以上述RBF神经网络模型均方根误差最小为适应度函数:

$$[0069] \quad f = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i' - y_i)^2} \quad (9)$$

[0070] 其中, y_i' 为等效模型输出数据, y_i 为样本值;

[0071] 粒子群的适应度方差为:

$$[0072] \quad \sigma_p^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{f_i - f_{avg}}{f} \right)^2 \quad (10)$$

[0073] 式中, σ_p^2 为粒子群的适应度方差, f_i 为第 i 个粒子的适应度, f_{avg} 为粒子的平均适应度, f 为一常数;

[0074] 每一次更新位置后,按照概率对粒子进行变异操作,其概率函数为:

$$[0075] \quad p = \begin{cases} \lambda & \sigma_p^2 < \mu \text{ 且 } |P_g - f_m| > \delta \\ 0 & \text{其他} \end{cases} \quad (11)$$

[0076] λ ($\lambda \in [0, 1]$) 为常数, μ 为远小于 σ_p^2 最大值的常数, δ 为收敛精度, P_g 为全局最优解, f_m 为理论最优值;满足变异操作概率条件时,产生随机数 $r \in [0, 1]$,若 $r < p$,对粒子 i 个体极值位置进行变异操作:

$$[0077] \quad b_i = b_i \times (1+d) \quad (12)$$

[0078] d 为[0, 1]之间符合标准正态分布的随机数;

[0079] 得到降维后的样本数据,将降维后的样本数据分为训练集和测试集。

[0080] 以上这些实施例应理解为仅用于说明本发明而不用于限制本发明的保护范围。在

阅读了本发明的记载的内容之后,技术人员可以对本发明作各种改动或修改,这些等效变化和修饰同样落入本发明权利要求所限定的范围。

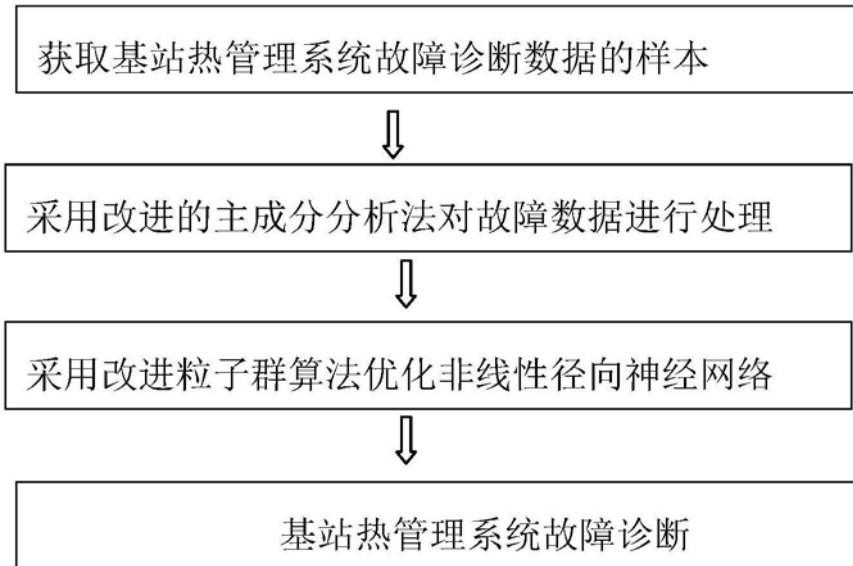


图1

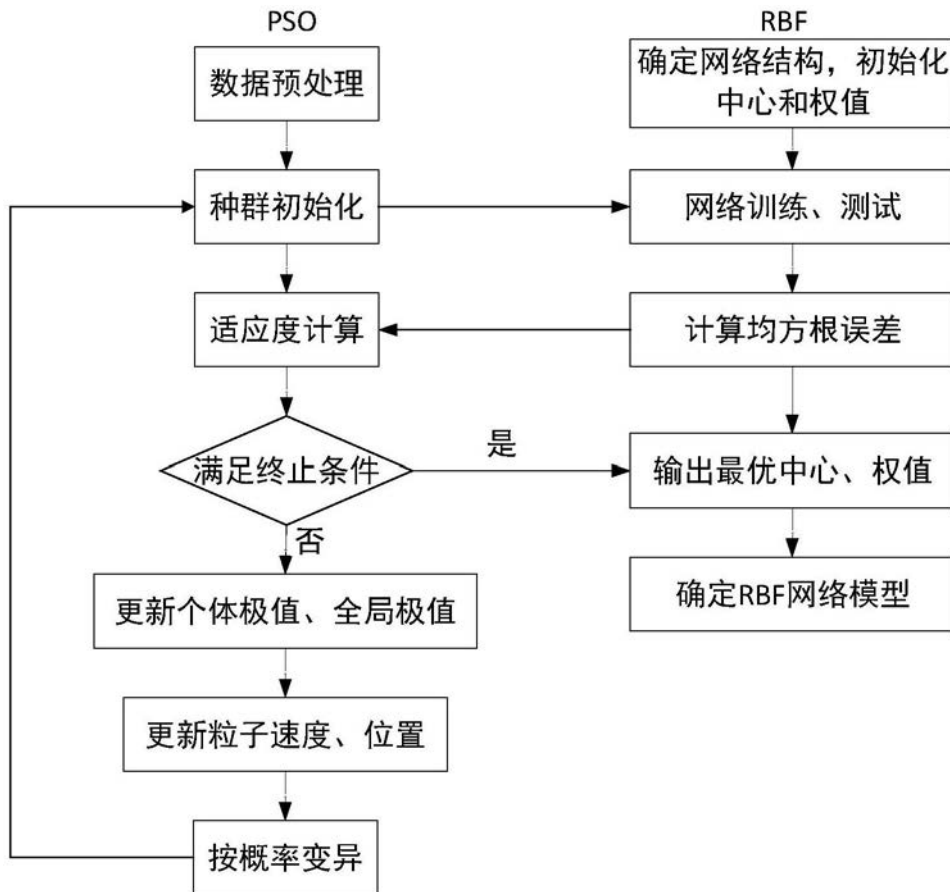


图2