



(12)发明专利申请

(10)申请公布号 CN 109447236 A

(43)申请公布日 2019.03.08

(21)申请号 201811138434.2

(22)申请日 2018.09.28

(71)申请人 重庆邮电大学

地址 400065 重庆市南岸区南山街道崇文路2号

(72)发明人 郑太雄 褚良宇 袁荣棣 杨新琴
侯晓康 张芹 田云浪

(74)专利代理机构 重庆市恒信知识产权代理有限公司 50102

代理人 刘小红 陈栋梁

(51)Int.Cl.

G06N 3/02(2006.01)

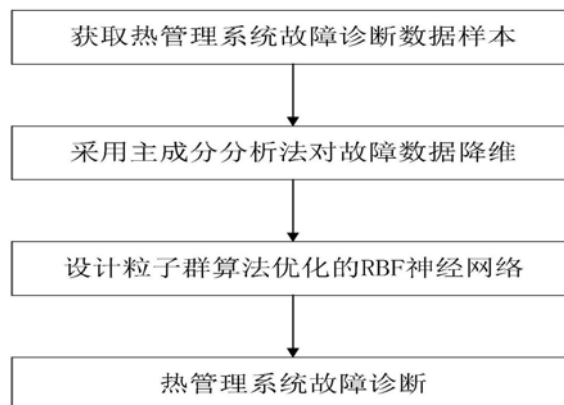
权利要求书3页 说明书8页 附图2页

(54)发明名称

一种混合动力汽车热管理系统的故障诊断方法

(57)摘要

本发明请求保护一种混合动力汽车热管理系统的故障诊断方法。包括以下步骤：选择热管理系统各部件出水口温度、压力、流量值作为输入变量，在热管理系统各回路布置温度、压力、流量传感器，分别采集正常情况和故障情况下的样本数据。采用主成分分析法对样本数据进行特征提取，得到降维后的样本数据，将样本数据分为训练集和测试集；设计RBF神经网络故障诊断模型，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；将训练好的RBF神经网络应用到混合动力汽车热管理系统的故障诊断，直接得到各执行件的故障状态。本发明利用各部件的实时参数对热管理系统进行状态和故障诊断，可以及时检测到热管理系统故障并直接确定故障位置。



1. 一种混合动力汽车热管理系统的故障诊断方法,其特征在于,包括以下步骤:

步骤1:选定热管理系统发动机回路、电机回路、电池回路的可测输出量,分别采集正常情况和故障情况下的样本数据;

步骤2:采用主成分分析法对步骤1所述采集到的热管理系统发动机回路、电机回路、电池回路的正常情况和故障情况的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;

步骤3:建立RBF神经网络故障诊断模型,采用粒子群优化算法优化神经网络故障诊断模型,将上述训练集数据用于RBF神经网络故障诊断模型的训练,得到优化后的RBF神经网络故障诊断模型;

步骤4:将优化后的RBF神经网络模型应用于混合动力汽车热管理系统故障诊断。

2. 根据权利要求1所述的一种混合动力汽车热管理系统的故障诊断方法,其特征在于,所述步骤1中的热管理系统包括热管理控制器、发动机热管理回路、电机热管理回路和电池热管理回路,热管理系统各回路执行部件包括发动机、发动机冷却水泵、电动机、电动机冷却水泵、电池、电池冷却水泵、风扇及散热器、节温器进水口和出水口的温度、压力、流量值共48个变量,作为样本数据集的样本空间,通过整车实验测试的方法获取故障诊断所需的样本数据,形成样本数据集。

3. 根据权利要求2所述的一种混合动力汽车热管理系统的故障诊断方法,其特征在于,所述步骤2: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:

上述故障样本数据为 $X (X \in \mathbb{R}^{n \times m})$, $\mathbb{R}^{n \times m}$ 为故障样本集, $n=48$ 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:

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

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

4. 根据权利要求3所述的一种混合动力汽车热管理系统的故障诊断方法,其特征在于,所述累计均方差贡献率设定值 $d_{\text{设}}=85\%$ 。

5. 根据权利要求3所述的一种混合动力汽车热管理系统的故障诊断方法,其特征在于,所述步骤3:建立RBF神经网络故障诊断模型具体包括:RBF神经网络的输入为:

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

其中, n 为输入节点个数, X 为上述经过归一化和降维处理的混合动力汽车热管理系统的特征参数值;

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。

6. 根据权利要求5所述的一种混合动力汽车热管理系统的故障诊断方法,其特征在于,所述步骤3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 $(0 \sim 2)$ 、 $(0 \sim 2)$ 、 $(0 \sim 1)$ 、 $(0 \sim 1)$, 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:

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

$\lambda (\lambda \in [0, 1])$ 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。

一种混合动力汽车热管理系统的故障诊断方法

技术领域

[0001] 本发明属于混合动力汽车故障诊断领域,具体为一种混合动力汽车的热管理系统故障诊断方法。

背景技术

[0002] 随着汽车产量和保有量不断增加,全球变暖、空气污染、化石能源减少等问题日益严重,节能环保已成为当前汽车研究急需解决的问题之一。混合动力汽车充分利用发动机和电池、电机的工作特性,能够合理分配能源,在满足汽车动力性要求和行驶性能的前提下,能够有效地提高燃油经济性和清洁环保性,减少排放,被认为是当前节能减排的有效途径之一。

[0003] 目前,各国学者对热管理系统故障诊断进行了大量研究。文献[1]采用主成分分析法(PCA)将冷水机组的正常数据分解为主元子空间和残差子空间,使用残差子空间得分矩阵建立故障诊断的支持向量机模型,实验结果表明,相对传统支持向量机故障诊断模型,PCA算法对小幅故障检测效率的提高效果显著。文献[2]针对多联机制冷剂充注量故障,使用PCA算法对原始数据进行降维处理,利用决策树算法进行故障诊断,数据处理后的诊断结果准确率提高约3.32%。文献[3]将基于遗传算法和支持向量机的故障诊断方法应用于制冷机。采用遗传算法进行特征选择,以消除不相关和冗余特征,能够提高学习任务效率和预测准确性。文献[4]将卡尔曼滤波器和基于模型的预测控制器应用于核电站二次冷却回路的模型。采用基于卡尔曼的策略,对阀门子系统进行及时的故障检测和诊断。完整的策略能够充分响应各种干扰,从而有助于提高研究系统的弹性。

[0004] 文献[5]分别基于人工神经网络设计了船舶发动机冷却系统故障诊断策略。文献采用BP(Back Propagation)神经网络,给出故障模型和原因分析,训练并测试故障诊断系统。文献[6]通过对多种训练后的神经网络算法参数对比分析,最终选取基于平均方差最小Levenberg-Marquardt算法的BP神经网络算法来研究热泵系统故障诊断。再利用线性回归的方法分析基于该神经网络模型的预测输出和实验数值之间关系,结果表明模型能够准确、高效的预测该热泵供暖系统的性能特征。文献[7-8]针对离心式冷水机组的故障检测与诊断(FDD),开发了基于非线性径向神经网络(RBF)的在线故障检测与诊断策略。作者对MLR(多元线性回归),KRG和RBF(径向基神经网络)三种诊断模型进行分析,通过诊断性能的比较,发现基于RBF的策略在三种策略中诊断性能最好,其所提出的RBF-EWMA方法对于故障检测具有较强的鲁棒性。文献[1]将支持向量机应用于制冷机系统,有效的减少了计算量和节约了初始成本。将支持向量机与特征提取方法相结合使用,能很好的解决支持向量机在选取参数时具有很大盲目性的缺点,提高其实用性。文献[9]提出基于贝叶斯网络分类器(Bayes Network Classifier)的船舶柴油机冷却系统故障诊断的NB贝叶斯网络故障诊断模型和TAN故障诊断模型,这两种故障诊断模型均可通过不断积累完善训练样本,自动修正网络结构参数和概率分布参数,从而提高诊断效果。文献[10]利用FlowMaster流体仿真软件建立某实际冷却系统管网不同准确度下的水力模型。采用改进的灰色关联度分析法

(IGR2)对各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。实验结果表明,该故障诊断方法对模型误差具有一定的鲁棒性。在利用神经网络故障诊断模型对发动机冷却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神经网络用于冷却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。

[0005] 热管理系统包括:热管理控制器、发动机热管理回路、电机热管理回路和电池热管理回路。各回路有多个辅助装置和气路单元体有机组合,包括发动机、电动机、电池、水泵、风扇、散热器、节温器等等。通过整车实验测试的方法,获取故障诊断样本数据集;采用主成分分析法降低故障数据样本维度,达到特征提取的效果,设计RBF神经网络故障诊断模型,采用粒子群优化算法优化RBF神经网络参数,利用训练集数据训练RBF神经网络模型,得到热管理系统故障诊断算法。将诊断算法应用于混合动力汽车实车检测,实时监测热管理系统工作状态,能够提高汽车运行可靠性,确定故障位置,减少热管理系统的维修周期。

[0006] [1]李冠男,胡云鹏,陈焕新,等.基于PCA-SVDD的冷水机组故障检测方法[J].华中科技大学学报(自然科学版),2015(8):119-122.

[0007] [2]王江宇,陈焕新,刘江岩,等.基于PCA-DT的多联机制冷剂充注量故障诊断[J].华中科技大学学报(自然科学版),2016,44(7):1-4.

[0008] [3]Han H,Gu B,Wang T,et al.Important sensors for chiller fault detection and diagnosis(FDD)from the perspective of feature selection and machine learning[J].International Journal of Refrigeration,2011,34(2):586-599.

[0009] [4]Villez K,Venkatasubramanian V,Garcia H.Supervisory control of a pilot-scale cooling loop[J].Office of Scientific&Technical Information Technical Reports,2011.

[0010] [5]Zhou J,Xu L.The fault diagnosis of marine engine cooling system based on artificial neural network(ANN)[C]//The,International Conference on Computer and Automation Engineering.IEEE,2010:186-189.

[0011] [6]Wua J,Zhang G,Quan Z,et al.Artificial neural network analysis of the performance characteristics of a reversibly used cooling tower under cross flow conditions for heat pump heating system in winter[J].Energy&Buildings,2011,43(7):1685-1693.

[0012] [7]Tran D A T,Chen Y,Chau M Q,et al.A robust online fault detection and diagnosis strategy of centrifugal chiller systems for building energy efficiency[J].Energy&Buildings,2015,108(5):441-453.

[0013] [8]Tran D A T,Chen Y,Jiang C.Comparative investigations on reference models for fault detection and diagnosis in centrifugal chiller systems[J].Energy&Buildings,2016,133:246-256.

[0014] [9]曾谊晖,鄂加强,朱浩,等.基于贝叶斯网络分类器的船舶柴油机冷却系统故障诊断[J].中南大学学报(自然科学版),2010,41(4):1379-1384.

[0015] [10]刘倩,张扬,徐新华,等.模型准确性对系统管网泄漏诊断的影响分析[J].中国舰船研究,2016,11(6):118-123.

发明内容

[0016] 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混合动力汽车热管理系统的故障诊断方法。本发明的技术方案如下：

[0017] 一种混合动力汽车热管理系统的故障诊断方法，其包括以下步骤：

[0018] 步骤1：选定热管理系统发动机回路、电机回路、电池回路的可测输出量，分别采集正常情况和故障情况下的样本数据；

[0019] 步骤2：采用主成分分析法对步骤1所述采集到的热管理系统发动机回路、电机回路、电池回路的正常情况和故障情况的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；

[0020] 步骤3：建立RBF神经网络故障诊断模型，采用粒子群优化算法优化神经网络故障诊断模型，将上述训练集数据用于RBF神经网络故障诊断模型的训练，得到优化后的RBF神经网络故障诊断模型；

[0021] 步骤4：将优化后的RBF神经网络模型应用于混合动力汽车热管理系统故障诊断。

[0022] 进一步的，所述步骤1中的热管理系统包括热管理控制器、发动机热管理回路、电机热管理回路和电池热管理回路，热管理系统各回路执行部件包括发动机、发动机冷却水泵、电动机、电动机冷却水泵、电池、电池冷却水泵、风扇及散热器、节温器进水口和出水口的温度、压力、流量值共48个变量，作为样本数据集的样本空间，通过整车实验测试的方法获取故障诊断所需的样本数据，形成样本数据集。

[0023] 进一步的，所述步骤2：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：

[0024] 上述故障样本数据为 X ($X \in R^{n \times p}$)， $R^{n \times m}$ 为故障样本集， $n=48$ 为变量个数， m 为样本个数；

[0025] 采用均值标准差标准化方法处理故障样本数据；

[0026] 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：

$$[0027] \quad \Sigma = \frac{1}{m} \sum_{i=1}^n (x^{(i)})(x^{(i)})^T \quad (1)$$

[0028] 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；

[0029] 计算前 k 个主成分对总均方差的贡献率，均方差贡献率为：

$$[0030] \quad d_k = \frac{\lambda_k}{\sum_{j=1}^n \lambda_j} \quad (2),$$

[0031] 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；

[0032] 主成分值方程为:

$$[0033] \quad Z=U^T x \quad (3)$$

[0034] 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。

[0035] 进一步的,所述累计均方差贡献率设定值 $d_{\text{设}}=85\%$ 。

[0036] 进一步的,所述步骤3:建立RBF神经网络故障诊断模型具体包括:RBF神经网络的输入为:

$$[0037] \quad X=[x_1, x_2, \dots, x_n]^T \quad (4)$$

[0038] 其中,n为输入节点个数,X为上述经过归一化和降维处理的混合动力汽车热管理系统的特征参数值;

[0039] RBF神经网络的输出为 y_m ;

[0040] 隐含层的激励函数取高斯基函数,即:

$$[0041] \quad R_j(X-c_j)=\exp(-\|X-c_j\|/2\sigma_j^2), j=1,2,\dots,p \quad (5)$$

[0042] 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;

[0043] RBF神经网络的输入和输出之间的关系表达式为:

$$[0044] \quad y_i = \sum_{j=1}^p w_{ij} \exp(-\|x-c_j\|^2/2\sigma_j^2), i=1,2,\dots,m \quad (6)$$

[0045] 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。

[0046] 进一步的,所述步骤3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:

$$[0047] \quad v_{ij}^{k+1} = w_p v_{ij}^k + c_1 r_1 (P_{ij}^k - b_{ij}^k) + c_2 r_2 (P_{gj}^k - b_{ij}^k) \quad (7)$$

$$[0048] \quad b_{ij}^{k+1} = b_{ij}^k + v_{ij}^{k+1} \quad (8)$$

[0049] 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;

[0050] 以上述RBF神经网络模型均方根误差最小为适应度函数:

$$[0051] \quad f = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i' - y_i)^2} \quad (9)$$

[0052] 其中, y_i' 为等效模型输出数据, y_i 为样本值;

[0053] 粒子群的适应度方差为:

$$[0054] \quad \sigma_p^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{f_i - f_{\text{avg}}}{f} \right)^2 \quad (10)$$

[0055] 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;

[0056] 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:

$$[0057] \quad p = \begin{cases} \lambda & \sigma_p^2 < \mu \text{ 且 } |P_g - f_m| > \delta \\ 0 & \text{其他} \end{cases} \quad (11)$$

[0058] 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:

$$[0059] \quad b_i = b_i \times (1+d) \quad (12)$$

[0060] d 为 $[0, 1]$ 之间符合标准正态分布的随机数;

[0061] 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。

[0062] 本发明的优点及有益效果如下:

[0063] (1) 本发明采用主成分分析法对故障样本数据进行降维处理, 降低了RBF神经网络输入数据的冗余性。

[0064] (2) 设计RBF神经网络对混合动力汽车热管理系统进行故障诊断, 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。

[0065] (3) 将训练好的RBF神经网络应用到混合动力汽车热管理系统的故障诊断, 将热管理系统各执行件采集到的冷却液温度、压力、流量信号作为输入, 能够直接得到各执行件的故障状态, 直接定位热管理系统的故障部件。

[0066] 本发明的创新点包括: 使用主成分分析算法对发动机冷却系统参数进行降维, 减少了模型的输入参数; 使用改进的粒子群算法对RBF神经网络故障诊断模型参数优化, 得到最优模型参数。

附图说明

[0067] 图1是本发明提供优选实施例混合动力汽车热管理系统的故障诊断方法流程图;

[0068] 图2为主成分分析流程图;

[0069] 图3为粒子群算法优化的RBF神经网络建模流程图。

具体实施方式

[0070] 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。

[0071] 本发明解决上述技术问题的技术方案是:

[0072] 本发明所述的混合动力汽车热管理系统的故障诊断方法包括故障数据获取和故障诊断算法设计两大部分, 故障数据获取包括: 选择热管理系统各回路执行部件, 包括发动机、发动机冷却水泵、电动机、电动机冷却水泵、电池、电池冷却水泵、风扇及散热器、节温器进水口和出水口的温度、压力、流量值共48个变量, 作为样本数据集的样本空间。在热管理系统各回路上布置温度、压力、流量传感器, 实时检测并采集所需物理量的数值; 通过整

车实验测试的方法获取故障诊断所需的样本数据。

[0073] 故障诊断算法设计包括:采用主成分分析法对所述故障数据样本进行特征提取,得到降维后的样本数据,将故障样本数据分为样本集和数据集;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;将训练好的RBF神经网络应用到混合动力汽车热管理系统的故障诊断,将热管理系统各执行件采集到的冷却液温度、压力、流量信号作为输入,能够直接得到各执行件的故障状态。

[0074] 如图1所示,本发明实现混合动力汽车热管理系统的故障诊断方法包括如下4个步骤:

[0075] 步骤1,选定热管理系统各部件的可测输出量,通过实验方法获取故障诊断所需的样本数据;选择热管理系统各回路执行部件,包括发动机、电动机、电池、电子水泵、风扇及散热器、节温器进出水口的温度、压力、流量及其变化参数等变量,作为样本数据集的样本空间。通过整车实验测试的方法获取故障诊断所需的样本数据。

[0076] 步骤2,采用主成分分析法对故障样本数据进行预处理:先采用正常情况下混合动力汽车热管理系统样本数据建立主元模型,然后利用主元模型对故障样本数据处理,得到降维后的故障样本数据,将故障样本数据分为样本集和数据集;

[0077] 步骤3:将所述样本集数据输入到建立好的RBF神经网络中,得到所述RBF神经网络的输出,利用训练好的RBF神经网络进行故障诊断。

[0078] 步骤4:将上述RBF神经网络模型应用于混合动力汽车热管理系统故障诊断:使用测试集样本数据对所述RBF神经网络故障诊断模型进行检测,将训练后的故障诊断模型应用于实车,对混合动力汽车热管理系统进行实时的故障诊断,并在故障发生时确定故障位置。

[0079] 如图2所示对于步骤2所述主成分分析法对样本数据降维的具体方法为:

[0080] 上述故障样本数据为 $X (X \in R^{n \times p})$, n 为变量个数, p 为样本个数;

[0081] 采用均值标准差标准化方法处理故障样本数据;

[0082] 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,协方差矩阵可求解为:

$$[0083] \quad \Sigma = \frac{1}{m} \sum_{i=1}^n (x^{(i)})(x^{(i)})^T \quad (1)$$

[0084] 其特征值为 $\lambda_i (i=1, 2, \dots, n)$, 每个特征值对应一个特征向量;

[0085] 计算前 k 个主成分对总均方差的贡献率,均方差贡献率为:

$$[0086] \quad d_k = \frac{\lambda_k}{\sum_{j=1}^n \lambda_j} \quad (2)$$

[0087] 取累计均方差贡献率大于85%,得到 k 值为主成分个数;

[0088] 主成分值方程为:

$$[0089] \quad Z = U^T x \quad (3)$$

[0090] 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。

[0091] 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。

[0092] 如图3所示对于步骤3所述RBF神经网络故障诊断算法具体方法为:

[0093] RBF神经网络的输入为:

$$[0094] \quad x = [x_1, x_2, \dots, x_n]^T \quad (4)$$

[0095] 其中, n 为输入节点个数, x 为上述经过归一化和降维处理的混合动力汽车热管理系统的特征参数值;

[0096] RBF神经网络的输出为 y_m ;

[0097] 其中, y_m 值为0或1, 0表示正常, 1表示故障, 对应为各执行件的故障状态;

[0098] 隐含层的激励函数取高斯基函数, 即:

$$[0099] \quad R_j(X - c_j) = \exp(-\|X - c_j\| / 2\sigma_j^2), j = 1, 2, \dots, p \quad (5)$$

[0100] 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;

[0101] RBF神经网络的输入和输出之间的关系表达式为:

$$[0102] \quad y_i = \sum_{j=1}^p w_{ij} \exp(-\|x - c_j\|^2 / 2\sigma_j^2), i = 1, 2, \dots, m \quad (6)$$

[0103] 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。

[0104] 进一步的, 所述步骤4中确定的粒子群PSO算法包括: 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:

$$[0105] \quad v_{ij}^{k+1} = w_p v_{ij}^k + c_1 r_1 (P_{ij}^k - b_{ij}^k) + c_2 r_2 (P_{gj}^k - b_{ij}^k) \quad (7)$$

$$[0106] \quad b_{ij}^{k+1} = b_{ij}^k + v_{ij}^{k+1} \quad (8)$$

[0107] 其中, 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, 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;

[0108] 以上述RBF神经网络模型均方根误差最小为适应度函数:

$$[0109] \quad f = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i' - y_i)^2} \quad (9)$$

[0110] 其中, y_i' 为等效模型输出数据, y_i 为样本值;

[0111] 粒子群的适应度方差为:

$$[0112] \quad \sigma_p^2 = \frac{1}{n} \sum_{i=1}^n \left(\frac{f_i - f_{avg}}{f} \right)^2 \quad (10)$$

[0113] 式中, 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;

[0114] 每一次更新位置后, 按照一定概率对粒子进行变异操作, 其概率函数为:

$$[0115] \quad p = \begin{cases} \lambda & \sigma_p^2 < \mu \text{ 且 } |P_g - f_m| > \delta \\ 0 & \text{其他} \end{cases} \quad (11)$$

[0116] 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, 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:

$$[0117] \quad b_i = b_i \times (1+d) \quad (12)$$

[0118] d 为 $[0, 1]$ 之间符合标准正态分布的随机数。

[0119] 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。

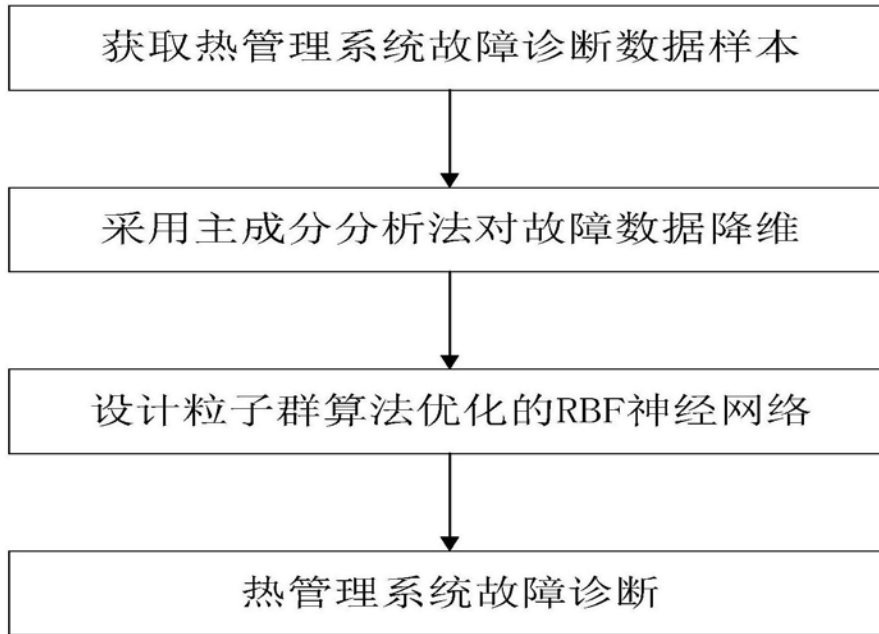


图1

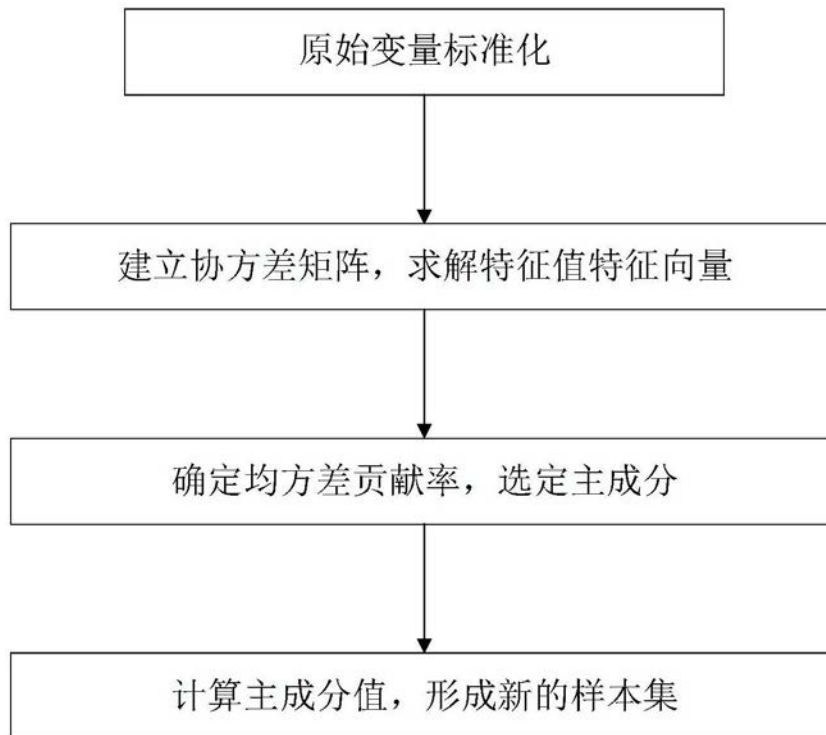


图2

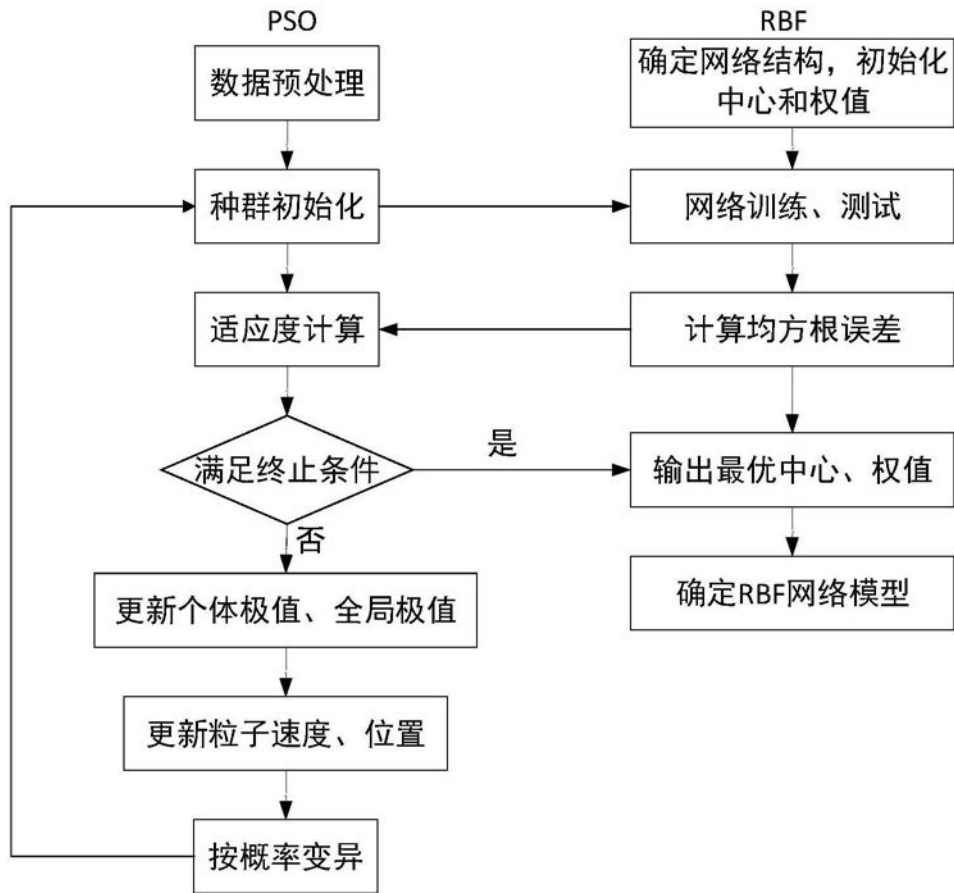


图3