



(12)发明专利申请

(10)申请公布号 CN 105911975 A

(43)申请公布日 2016.08.31

(21)申请号 201610231577.2

(22)申请日 2016.04.14

(71)申请人 南京航空航天大学  
地址 210016 江苏省南京市秦淮区御道街29号

(72)发明人 鲁峰 王亚凡 黄金泉 黄一桓 江春宇

(74)专利代理机构 南京瑞弘专利商标事务所  
(普通合伙) 32249

代理人 陈琛

(51)Int.Cl.  
G05B 23/02(2006.01)

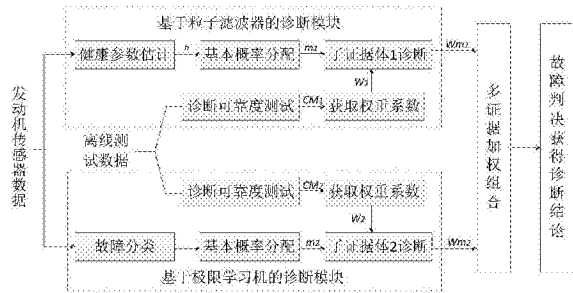
权利要求书3页 说明书10页 附图3页

(54)发明名称

一种航空发动机气路故障融合诊断方法

(57)摘要

本发明涉及基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法,解决了采用单一类型的故障诊断方法精度不高、多方法融合过程中存在证据冲突的问题;分别构建基于粒子滤波器和极限学习机的非线性局部诊断模块,采用自适应加权D-S证据理论对局部诊断结果进行融合。提出发动机故障的多方法融合诊断结构,通过混淆矩阵离线获取基于粒子滤波器和极限学习机的局部诊断系统对各故障模式的诊断可靠度,根据诊断可靠度赋予证据体不同的权值系数,有效降低了证据冲突,提高了发动机气路部件故障融合诊断的精度。



1. 一种航空发动机气路故障融合诊断方法,其特征在于:包括如下步骤:

步骤001:分别构建基于极限学习机的局部诊断方法所对应的局部诊断模块和基于粒子滤波器的局部诊断方法所对应的局部诊断模块;

步骤002:对于n类航空发动机的典型故障模式,每类故障模式随机选取m个故障样本,采用基于粒子过滤器和极限学习机的局部诊断方法分别对 $n \times m$ 个故障样本进行诊断,对于每种局部诊断方法,分别得到代表该种局部诊断方法对于各故障模式的诊断准确率的一个 $n \times n$ 维混淆矩阵CM:

$$CM = \begin{bmatrix} cm_{11} & cm_{12} & \cdots & cm_{1n} \\ cm_{21} & cm_{22} & \cdots & cm_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ cm_{n1} & cm_{n2} & \cdots & cm_{nn} \end{bmatrix}$$

式中, $cm_{ij}$ 表示第i类故障模式被所使用的局部诊断方法判断成第j类故障模式的样本数占第i类故障模式样本总数的百分比,对角线上的元素即为所使用的局部诊断方法对于各故障模式的诊断准确率, $i=1,2,\dots,n,j=1,2,\dots,n$ ;则能够得到局部诊断方法对第j

类故障模式的诊断结果可靠度 $R_j$ 为:

$$R_j = \frac{cm_{jj}}{\sum_{i=1}^n cm_{ij}};$$

步骤003:对发动机传感器测量信号进行采集、预处理,分别输入至两个局部诊断模块中,采用基于粒子过滤器和极限学习机的局部诊断方法进行发动机故障诊断;其中,粒子过滤器直接利用发动机非线性模型估计发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数;极限学习机根据故障时刻的发动机传感器数据对当前发动机故障进行分类,得到当前故障属于发动机各故障模式的基本概率;

步骤004:基于自适应加权D-S证据理论,对两个局部诊断模块的诊断结果进行融合;根据粒子过滤器和极限学习机两种局部诊断方法对不同故障模式的诊断可靠度,分别对步骤003中两个证据体得到的基本概率赋值进行加权处理;将证据体的加权概率分配结果输入至融合中心,根据Dempster合成规则,对加权概率分配结果进行融合,从而得到多证据体加权融合后的最终诊断结论。

2. 根据权利要求1所述一种航空发动机气路故障融合诊断方法,其特征在于:步骤001中所述,构建基于极限学习机的局部诊断模块,具体构建方法如下:将航空发动机的风扇、压气机、高压涡轮和低压涡轮4个核心部件分为正常和故障两类故障等级,共有4种单故障模式和6种双故障模式;在发动机地面稳态工作点,即: $H=0m, Ma=0$ 点,对发动机模型依次注入这10种类型的故障,每种故障性能参数的变化量从0.2%开始,每次增加0.2%等间隔增加到4%,供油量从1.58kg/s开始,每间隔0.1kg/s增加到2.48kg/s,共获得2000组训练数据,所有的数据都归一化到 $[0,1]$ 区间,在归一化数据中加入高斯噪声;以发生气路故障后的发动机传感器测量值为输入,以相应的故障模式为输出,利用生成的训练样本数据对极限学习机进行离线训练;将训练后的极限学习机用于航空发动机气路部件故障的诊断。

3. 根据权利要求1所述一种航空发动机气路故障融合诊断方法,其特征在于:步骤001中所述,构建基于粒子滤波器的局部诊断模块,具体构建方法如下:将传感器测量参数输入

至粒子滤波器中,估计出发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数,用于航空发动机气路部件故障的诊断。

4.根据权利要求1所述一种航空发动机气路故障融合诊断方法,其特征在于:步骤003中所述,粒子滤波器直接利用发动机非线性模型估计发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数;具体包括如下内容:

将传感器测量参数输入至粒子滤波器故障诊断子系统中,估计风扇SE<sub>1</sub>、压气机SE<sub>2</sub>、高压涡轮SE<sub>3</sub>和低压涡轮SE<sub>4</sub>这4个发动机核心部件的效率蜕化量 $h=[\Delta SE_1 \ \Delta SE_2 \ \Delta SE_3 \ \Delta SE_4]^T$ ,得到连续的健康参数估计值;以效率蜕化量1%为蜕化程度小至蜕化程度大的过渡点,即发动机部件性能参数小蜕化和大蜕化的性能蜕化区间分别为(0,1%)、[1%,5%],设计出对应的模糊逻辑规则:

- 1)若  $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=S$ ,则风扇故障;
- 2)若  $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=S$ ,则压气机故障;
- 3)若  $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=S$ ,则高压涡轮故障;
- 4)若  $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=L$ ,则低压涡轮故障;
- 5)若  $\Delta SE_1=L, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=S$ ,则风扇和压气机故障;
- 6)若  $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=S$ ,则风扇和高压涡轮故障;
- 7)若  $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=L$ ,则风扇和低压涡轮故障;
- 8)若  $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=L, \Delta SE_4=S$ ,则压气机和高压涡轮故障;
- 9)若  $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=L$ ,则压气机和低压涡轮故障;
- 10)若  $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=L$ ,则高压涡轮和低压涡轮故障;

其中,S代表小蜕化,L代表大蜕化;通过模糊逻辑规则将连续的效率蜕化量转化为发动机部件故障程度及相应的概率函数。

5.根据权利要求1所述一种航空发动机气路故障融合诊断方法,其特征在于:所述步骤004具体包括如下内容:基于自适应加权D-S证据理论,对两个局部诊断模块的诊断结果进行融合;在多证据体非线性融合过程中,定义辨识框架 $\Theta$ 上的权重分配函数 $W(\cdot)$ 为:

$$W(A) = \frac{k \cdot R^3(A)}{\sum_{A \in \Theta} R^3(A)}$$

$$k = \begin{cases} 2 & \text{rank} = 1, 2, 3; \\ 1 & \text{other} \end{cases}$$

式中,k为加权因子,rank为该证据体对于各故障模式的基本概率赋值从大到小的排序情况;

考虑到各局部诊断证据对不同故障模式的诊断可靠度不同,对基本概率赋值函数进行加权处理: $W_m(A) = \frac{W(A) \cdot m(A)}{\sum_{A \in \Theta} W(A) \cdot m(A)}$ ,映射 $W_m: 2^\Theta \rightarrow [0, 1]$ 为辨识框架 $\Theta$ 上的加权概率赋值函数;

局部诊断结果经过加权处理后,传输至融合中心,根据D-S合成规则进行融合,自适应加权D-S合成规则为:

$$Wm(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} Wm_1(A_i)Wm_2(B_j)}{1-K} & A \neq \emptyset \\ 0 & A = \emptyset \end{cases}$$

式中,  $K = \sum_{A_i \cap B_j = \emptyset} Wm_1(A_i)Wm_2(B_j)$ 。

## 一种航空发动机气路故障融合诊断方法

### 技术领域

[0001] 本发明涉及一种基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法,其属于航空发动机故障诊断领域。

### 背景技术

[0002] 航空发动机为飞机提供动力,其安全可靠性是保障飞行安全的关键。而航空发动机由于机械结构非常复杂,且工作在高温、高压等恶劣环境中,故障率较高,据美国一项统计表明,发动机故障导致的飞行事故占全部事故的30%左右。发动机健康管理技术是保证发动机可靠运行及预防发动机故障发生的重要手段,该技术通过利用发动机各种状态信息(维修记录、传感器测量数据等),对发动机的工作状态进行监视,对故障进行诊断,对使用寿命进行预测。发动机健康管理主要包括气路分析(GPA)、振动及滑油监视、寿命管理等方面。相关研究表明,发动机总体故障约90%发生在气路部件中,因此气路分析在发动机健康管理中占有重要的地位。典型的气路健康诊断方法包括基于模型的、数据驱动的方法,其中基于模型方法的发动机气路故障诊断效果容易受到建模的不确定性、不确定性滤波估计和系统噪声等因素的影响,诊断结果受扰严重。数据驱动的诊断方法以发动机部件蜕化数据作为故障诊断的依据,需大量的已有故障数据支撑,但对于航空发动机一类的故障小样本问题,故障模式及部件蜕化数据有限,因此这种方法对未知的故障模式诊断能力较差。

[0003] 基于模型和数据驱动的发动机故障诊断方法分别存在着不同的缺陷,而且由于发动机工作状态复杂,影响因素较多,气路故障诊断使用的数据也越来越多,仅利用单一的故障特征和故障诊断方法难以有效的完成发动机气路故障诊断。D-S证据理论作为一种信息组合方法,可以将不同的证据体通过Dempster规则合并成一个新的证据体,具有很强的处理不确定性信息的能力。采用D-S证据理论,将基于模型的故障诊断方法和数据驱动的故障诊断方法得到的发动机部件健康状况证据体结合起来,可以克服发动机故障诊断中单个诊断方法存在的问题。粒子滤波(PF)是近年来兴起的一种非线性滤波方法,它直接利用发动机非线性模型,以样本均值代替积分运算,利用粒子及其权重组成的离散随机测度近似状态的后验概率分布,适用于非线性较强的系统,而且对噪声分布特性没有限制,适合用于处理发动机这种处于复杂噪声影响之下的非线性较强的系统。极限学习机作为一种特殊类型的单隐层前向神经网络,可以任意设定隐节点的输入权值和偏置,通过训练获得最优的输出权值。与神经网络等传统的机器学习算法相比,极限学习机学习速度快,泛化能力好。

[0004] D-S合成规则在局部诊断结果冲突较大的情况下,常会出现合成结论有悖常理的现象,为了解决这一问题,国内外学者分别从证据冲突系数、证据合成公式或证据距离等层面进行了改进。但是这些方法都旨在合成规则上进行改进,却忽略了证据间冲突的来源。对于发动机气路部件故障融合诊断系统,不同的局部诊断系统由于特征域和诊断机理的不同,对于各故障模式的诊断可靠度并不相同,导致不同的局部诊断结果之间存在冲突。

### 发明内容

[0005] 针对现有技术存在的问题,本发明提供基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法,构建基于粒子滤波器和极限学习机这两种非线性故障诊断方法的并行诊断模块,采用自适应加权D-S证据理论对局部诊断的结果进行融合,克服了现有技术中的不足,用于发动机寿命期内的气路部件的健康诊断,从而保证发动机更加安全可靠的运行。

[0006] 本发明采用如下技术方案:一种航空发动机气路故障融合诊断方法,包括如下步骤:

[0007] 步骤001:分别构建基于极限学习机的局部诊断方法所对应的局部诊断模块和基于粒子滤波器的局部诊断方法所对应的局部诊断模块;

[0008] 步骤002:对于n类航空发动机的典型故障模式,每类故障模式随机选取m个故障样本,采用基于粒子滤波器和极限学习机的局部诊断方法分别对 $n \times m$ 个故障样本进行诊断,对于每种局部诊断方法,分别得到代表该种局部诊断方法对于各故障模式的诊断准确率的一个 $n \times n$ 维混淆矩阵CM:

$$[0009] \quad CM = \begin{bmatrix} cm_{11} & cm_{12} & \cdots & cm_{1n} \\ cm_{21} & cm_{22} & \cdots & cm_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ cm_{n1} & cm_{n2} & \cdots & cm_{nn} \end{bmatrix}$$

[0010] 式中, $cm_{ij}$ 表示第i类故障模式被所使用的局部诊断方法判断成第j类故障模式的样本数占第i类故障模式样本总数的百分比,对角线上的元素即为所使用的局部诊断方法对于各故障模式的诊断准确率, $i=1,2,\dots,n,j=1,2,\dots,n$ ;则能够得到局部诊断方法对

第j类故障模式的诊断结果可靠度 $R_j$ 为:

$$R_j = \frac{cm_{jj}}{\sum_{i=1}^n cm_{ij}};$$

[0011] 步骤003:对发动机传感器测量信号进行采集、预处理,分别输入至两个局部诊断模块中,采用基于粒子滤波器和极限学习机的局部诊断方法进行发动机故障诊断;其中,粒子滤波器直接利用发动机非线性模型估计发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数;极限学习机根据故障时刻的发动机传感器数据对当前发动机故障进行分类,得到当前故障属于发动机各故障模式的基本概率;

[0012] 步骤004:基于自适应加权D-S证据理论,对两个局部诊断模块的诊断结果进行融合;根据粒子滤波器和极限学习机两种局部诊断方法对不同故障模式的诊断可靠度,分别对步骤003中两个证据体得到的基本概率赋值进行加权处理;将证据体的加权概率分配结果输入至融合中心,根据Dempster合成规则,对加权概率分配结果进行融合,从而得到多证据体加权融合后的最终诊断结论。

[0013] 作为本发明的一种优选技术方案:步骤001中所述,构建基于极限学习机的局部诊断模块,具体构建方法如下:将航空发动机的风扇、压气机、高压涡轮和低压涡轮4个核心部件分为正常和故障两类故障等级,共有4种单故障模式和6种双故障模式;在发动机地面稳态工作点,即: $H=0m, Ma=0$ 点,对发动机模型依次注入这10种类型的故障,每种故障性能参数的变化量从0.2%开始,每次增加0.2%等间隔增加到4%,供油量从1.58kg/s开始,每间

隔0.1kg/s增加到2.48kg/s,共获得2000(10\*10\*20)组训练数据,所有的数据都归一化到[0,1]区间,在归一化数据中加入高斯噪声;以发生气路故障后的发动机传感器测量值为输入,以相应的故障模式为输出,利用生成的训练样本数据对极限学习机进行离线训练;将训练后的极限学习机用于航空发动机气路部件故障的诊断。

[0014] 作为本发明的一种优选技术方案:步骤001中所述,构建基于粒子滤波器的局部诊断模块,具体构建方法如下:将传感器测量参数输入至粒子滤波器中,估计出发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数,用于航空发动机气路部件故障的诊断。

[0015] 作为本发明的一种优选技术方案:步骤003中所述,粒子滤波器直接利用发动机非线性模型估计发动机健康参数,连续的健康参数估计值通过模糊逻辑转换成具体的发动机部件故障模式及相应的基本概率函数;具体包括如下内容:

[0016] 将传感器测量参数输入至粒子滤波器故障诊断子系统中,估计风扇SE<sub>1</sub>、压气机SE<sub>2</sub>、高压涡轮SE<sub>3</sub>和低压涡轮SE<sub>4</sub>这4个发动机核心部件的效率蜕化量 $h = [\Delta SE_1 \ \Delta SE_2 \ \Delta SE_3 \ \Delta SE_4]^T$ ,得到连续的健康参数估计值;以效率蜕化量1%为蜕化程度小至蜕化程度大的过渡点,即发动机部件性能参数小蜕化和大蜕化的性能蜕化区间分别为(0,1%)、[1%,5%],设计出对应的模糊逻辑规则:

[0017] 11)若 $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=S$ ,则风扇故障;

[0018] 12)若 $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=S$ ,则压气机故障;

[0019] 13)若 $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=S$ ,则高压涡轮故障;

[0020] 14)若 $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=L$ ,则低压涡轮故障;

[0021] 15)若 $\Delta SE_1=L, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=S$ ,则风扇和压气机故障;

[0022] 16)若 $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=S$ ,则风扇和高压涡轮故障;

[0023] 17)若 $\Delta SE_1=L, \Delta SE_2=S, \Delta SE_3=S, \Delta SE_4=L$ ,则风扇和低压涡轮故障;

[0024] 18)若 $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=L, \Delta SE_4=S$ ,则压气机和高压涡轮故障;

[0025] 19)若 $\Delta SE_1=S, \Delta SE_2=L, \Delta SE_3=S, \Delta SE_4=L$ ,则压气机和低压涡轮故障;

[0026] 20)若 $\Delta SE_1=S, \Delta SE_2=S, \Delta SE_3=L, \Delta SE_4=L$ ,则高压涡轮和低压涡轮故障;

[0027] 其中,S代表小蜕化,L代表大蜕化;通过模糊逻辑规则将连续的效率蜕化量转化为发动机部件故障程度及相应的概率函数。

[0028] 作为本发明的一种优选技术方案:所述步骤004具体包括如下内容:基于自适应加权D-S证据理论,对两个局部诊断模块的诊断结果进行融合;在多证据体非线性融合过程中,定义辨识框架 $\Theta$ 上的权重分配函数 $W(\cdot)$ 为:

$$[0029] \quad W(A) = \frac{k \cdot R^3(A)}{\sum_{A \in \Theta} R^3(A)}$$

$$[0030] \quad k = \begin{cases} 2 & \text{rank} = 1, 2, 3; \\ 1 & \text{other} \end{cases}$$

[0031] 式中,k为加权因子,rank为该证据体对于各故障模式的基本概率赋值从大到小的排序情况;

[0032] 考虑到各局部诊断证据对不同故障模式的诊断可靠度不同,对基本概率赋值函数

进行加权处理： $Wm(A) = \frac{W(A) \cdot m(A)}{\sum_{A \in \Theta} W(A) \cdot m(A)}$ ，映射  $Wm: 2^\Theta \rightarrow [0, 1]$  为辨识框架  $\Theta$  上的加权概率赋值函数；

[0033] 局部诊断结果经过加权处理后，传输至融合中心，根据D-S合成规则进行融合，自适应加权D-S合成规则为：

$$[0034] \quad Wm(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} Wm_1(A_i) Wm_2(B_j)}{1 - K} & A \neq \emptyset \\ 0 & A = \emptyset \end{cases}$$

[0035] 式中， $K = \sum_{A_i \cap B_j = \emptyset} Wm_1(A_i) Wm_2(B_j)$ 。自适应加权D-S证据理论通过对基本概率赋值函数进行加权处理，使得合理证据进一步加强，而不合理的证据被削弱。

[0036] 本发明所述基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法采用以上技术方案与现有技术相比，具有以下技术效果：本发明设计了航空发动机气路故障融合诊断结构，构建基于粒子滤波器和极限学习机这两种非线性故障诊断方法的并行诊断模块，采用自适应加权D-S证据理论对局部诊断的结果进行融合，克服了发动机故障诊断中单个诊断方法存在的问题，提高了诊断的精度和可靠性；为了解决多证据融合过程中证据严重冲突的问题，通过混淆矩阵获取基于粒子和极限学习机的局部诊断系统对各故障模式的诊断可靠度，从而在生成基本概率赋值函数时赋予不同的权值系数，使正确诊断的可信度能够提升，错误诊断的可信度下降，有效降低了证据冲突，提高了发动机气路部件故障融合诊断的精度。

## 附图说明

[0037] 图1是涡扇发动机气路工作截面标识图；

[0038] 图2是本发明设计基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法的诊断结构图；

[0039] 图3是  $\Delta SE_1$  的隶属度函数图。

[0040] 图4是风扇故障的隶属度函数图。

[0041] 图5是  $F_{10}$  故障模式下单个诊断及两种D-S证据理论方法融合结果对比。

## 具体实施方式

[0042] 下面结合说明书附图对本发明的具体实施方式作进一步详细的说明。

[0043] 对于航空发动机气路故障诊断方法来说，基于粒子滤波器的非线性故障诊断方法能从气动热力学原理上解释气路测量参数与气路健康状况之间的深层次关系，可以在包线内全状态下对整个性能变化范围进行定量诊断。但是由于其过度依赖于数学模型精度，而建模的不确定性、不确定性滤波估计和系统噪声等都将影响基于模型方法的发动机气路故障诊断效果。而基于极限学习机的非线性故障诊断方法以发动机部件蜕化数据作为故障诊断的依据，需大量的已有故障数据支撑，但对于航空发动机一类的故障小样本问题，故障模式及部件蜕化数据有限，因此这种方法对未知的故障模式诊断能力较差。采用D-S证据理



论,对粒子滤波器和极限学习机这两种非线性故障诊断方法得到的发动机部件健康诊断结果进行融合,能够克服发动机故障诊断中单个诊断方法存在的问题。

[0044] 本发明所涉及实施例所应用的涡扇发动机气路的工作截面如图1所示,主要部件包括进气道、风扇、压气机、燃烧室、高压涡轮、低压涡轮、混合室、加力燃烧室和尾喷管等,本发明所设计的航空发动机气路部件健康诊断方法在实际应用过程当中,首先针对航空发动机各个指定气路部件(风扇、压气机、高压涡轮、低压涡轮),分别设置用于指定参数测量的各个传感器,这里我们所设计的传感器分别用于风扇转速、压气机转速、风扇出口温度、风扇出口压力、压气机出口温度、压气机出口压力、高压涡轮出口温度、混合室进口温度;粒子滤波器和极限学习机根据故障时的发动机传感器数据分别对故障进行诊断,得到局部诊断结论,再采用自适应加权D-S证据理论对局部诊断结果进行融合,得到最终的诊断结论,如图2所示;所述故障诊断方法包括如下步骤:

[0045] 步骤001:构建基于极限学习机的局部诊断模块:将航空发动机的风扇、压气机、高压涡轮和低压涡轮4个核心部件分为正常和故障两类故障等级,共有4种单故障模式和6种双故障模式;在发动机地面稳态工作点( $H=0m, Ma=0$ ),对发动机模型依次注入这10种类型的故障,每种故障性能参数的变化量从0.2%开始,每次增加0.2%等间隔增加到4%,供油量从1.58kg/s开始,每间隔0.1kg/s增加到2.48kg/s,共获得2000( $10*10*20$ )组训练数据,所有的数据都归一化到 $[0,1]$ 区间,在归一化数据中加入高斯噪声;以发生气路故障后的发动机传感器测量值为输入,以相应的故障模式为输出,利用生成的训练样本数据对极限学习机进行离线训练;将训练后的极限学习机用于航空发动机气路部件故障的诊断;

[0046] 对于N个训练样本的集合 $\{(x_i, d_i) | i=1, 2, \dots, N\}$ ,其中输入 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$ ,输出 $d_i = [d_{i1}, d_{i2}, \dots, d_{in}]^T \in \mathbb{R}^m$ ;设存在拟合函数 $f: x_i \rightarrow d_i$ ,在具有L个隐层神经元的单

隐层前向神经网络,拟合函数能够表示为:
$$f(x) = \sum_{j=1}^L g(a_j^T x + b_j) \beta_j = h^T(x) \beta$$
  $a_j = [a_{1j}, a_{2j}, \dots, a_{nj}]^T$ 为连接第j个隐含节点的输入权值向量; $b_j$ 为第j个隐含节点偏置; $\beta = [\beta_1 \ \beta_2 \ \dots \ \beta_L]^T$ 为输出权值向量, $h(x) = [g(a_1^T x + b_1) \ \dots \ g(a_L^T x + b_L)]^T$ 为特征映射, $g(x)$ 为隐层神经元激活函数;随机选定 $(a_i, b_i)$ ,将学习样本映射到一个新的特征空间,生成线性方程组: $h(x) = [g(a_1^T x + b_1) \ \dots \ g(a_L^T x + b_L)]^T$ ,在新的特征空间内,采用最小二乘法求解线性方程组;输出权值能够通过最小二范数最小二乘解得到: $\beta = H^+ d$ ,  $H^+$ 是H的Moore-Penrose(MP)广义逆。

[0047] 步骤002:对于n类航空发动机的典型故障模式,每类故障模式随机选取m个故障样本,采用基于粒子滤波器和极限学习机的局部诊断方法分别对 $n \times m$ 个故障样本进行诊断,对于每种局部诊断方法,分别得到代表该种局部诊断方法对于各故障模式的诊断准确率的一个 $n \times n$ 维混淆矩阵CM:

$$[0048] \quad CM = \begin{bmatrix} cm_{11} & cm_{12} & \dots & cm_{1n} \\ cm_{21} & cm_{22} & \dots & cm_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ cm_{n1} & cm_{n2} & \dots & cm_{nn} \end{bmatrix}$$

[0049] 式中, $cm_{ij}$ 表示第i类故障模式被所使用的局部诊断方法判断成第j类故障模式的

样本数占第*i*类故障模式样本总数的百分比,对角线上的元素即为所使用的局部诊断方法对于各故障模式的诊断准确率;则能够得到局部诊断方法对第*j*类故障模式的诊断结果可靠度 $R_j$ 为:

$$[0050] \quad R_j = \frac{cm_{jj}}{\sum_{i=1}^n cm_{ij}}$$

[0051] 步骤003:对发动机传感器测量信号进行采集、预处理,将传感器测量参数输入至粒子滤波器故障诊断子系统中,估计风扇、压气机、高压涡轮和低压涡轮4个发动机核心部件的效率蜕化量 $h = [\Delta SE_1 \ \Delta SE_2 \ \Delta SE_3 \ \Delta SE_4]^T$ ,得到连续的健康参数估计值;以效率蜕化量1%为蜕化程度小至蜕化程度大的过渡点,即发动机部件性能参数小蜕化和大蜕化的性能蜕化区间分别为(0,1%)、[1%,5%],设计出对应的模糊逻辑规则:

[0052] 21)若 $\Delta SE_1=L$ (大), $\Delta SE_2=S$ (小), $\Delta SE_3=S$ (小), $\Delta SE_4=S$ (小),则风扇故障;

[0053] 22)若 $\Delta SE_1=S$ (小), $\Delta SE_2=L$ (大), $\Delta SE_3=S$ (小), $\Delta SE_4=S$ (小),则压气机故障;

[0054] 23)若 $\Delta SE_1=S$ (小), $\Delta SE_2=S$ (小), $\Delta SE_3=L$ (大), $\Delta SE_4=S$ (小),则高压涡轮故障;

[0055] 24)若 $\Delta SE_1=S$ (小), $\Delta SE_2=S$ (小), $\Delta SE_3=S$ (小), $\Delta SE_4=L$ (大),则低压涡轮故障;

[0056] 25)若 $\Delta SE_1=L$ (大), $\Delta SE_2=L$ (大), $\Delta SE_3=S$ (小), $\Delta SE_4=S$ (小),则风扇和压气机故障;

[0057] 26)若 $\Delta SE_1=L$ (大), $\Delta SE_2=S$ (小), $\Delta SE_3=L$ (大), $\Delta SE_4=S$ (小),则风扇和高压涡轮故障;

[0058] 27)若 $\Delta SE_1=L$ (大), $\Delta SE_2=S$ (小), $\Delta SE_3=S$ (小), $\Delta SE_4=L$ (大),则风扇和低压涡轮故障;

[0059] 28)若 $\Delta SE_1=S$ (小), $\Delta SE_2=L$ (大), $\Delta SE_3=L$ (大), $\Delta SE_4=S$ (小),则压气机和高压涡轮故障;

[0060] 29)若 $\Delta SE_1=S$ (小), $\Delta SE_2=L$ (大), $\Delta SE_3=S$ (小), $\Delta SE_4=L$ (大),则压气机和低压涡轮故障;

[0061] 30)若 $\Delta SE_1=S$ (小), $\Delta SE_2=S$ (小), $\Delta SE_3=L$ (大), $\Delta SE_4=L$ (大),则高压涡轮和低压涡轮故障。

[0062]  $\Delta SE_1$ 的隶属度函数如图3所示,风扇故障的隶属度函数如图4所示。通过模糊逻辑规则将连续的效率蜕化量转化为发动机部件故障程度及相应的概率函数。

[0063] 利用训练后的极限学习机进行故障分类,得到当前故障属于各故障模式的基本概率。

[0064] 步骤004:基于自适应加权D-S证据理论,对两个局部诊断模块的诊断结果进行融合;根据粒子滤波器和极限学习机两种局部诊断方法对不同故障模式的诊断可靠度,分别对步骤003中两个证据体得到的基本概率赋值进行加权处理;将证据体的加权概率分配结果输入至融合中心,根据Dempster合成规则,对加权概率分配结果进行融合,从而得到多证据体加权融合后的最终诊断结论。

[0065] 在多证据体融合过程中,定义辨识框架 $\Theta$ 上的权重分配函数 $W(\cdot)$ 为:

[0066] 
$$W(A) = \frac{k \cdot R^3(A)}{\sum_{A \subset \Theta} R^3(A)}$$

[0067] 
$$k = \begin{cases} 2 & rank = 1, 2, 3; \\ 1 & other \end{cases}$$

[0068] 式中,k为加权因子,rank为该证据体对于各故障模式的基本概率赋值从大到小的排序情况;考虑到各局部诊断证据对不同故障模式的诊断可靠度不同,对基本概率赋值函数进行加权处理:

$$Wm(A) = \frac{W(A) \cdot m(A)}{\sum_{A \subset \Theta} W(A) \cdot m(A)},$$
 映射  $Wm: 2^\Theta \rightarrow [0, 1]$  为辨识框架  $\Theta$  上的加权概率

赋值函数;

[0069] 局部诊断结果经过加权处理后,传输至融合中心,根据D-S合成规则进行融合,自适应加权D-S合成规则为:

[0070] 
$$Wm(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} Wm_1(A_i)Wm_2(B_j)}{1 - K} & A \neq \emptyset \\ 0 & A = \emptyset \end{cases}$$

[0071] 式中,  $K = \sum_{A_i \cap B_j = \emptyset} Wm_1(A_i)Wm_2(B_j)$ ; 自适应加权D-S证据理论通过对基本概率赋值函数进行加权处理,使得合理证据进一步加强,而不合理的证据被削弱。

[0072] 为了验证本发明所设计基于自适应加权D-S证据理论的航空发动机气路故障融合诊断方法的有效性,在MATLAB环境下进行气路健康诊断的数字仿真。

[0073] 基于粒子滤波器的局部诊断作为证据体1,在发动机地面工作点(H=0m, Ma=0, Wf=1.65kg/s)选取发动机模型各故障模式下典型样本各100组进行测试,得到证据体1的混淆矩阵CM<sub>1</sub>:

[0074] 
$$CM_1 = \begin{bmatrix} 81 & 2 & 10 & 1 & 0 & 0 & 6 & 0 & 0 & 0 \\ 0 & 94 & 0 & 0 & 0 & 0 & 0 & 0 & 6 & 0 \\ 0 & 1 & 61 & 2 & 5 & 6 & 0 & 0 & 0 & 25 \\ 1 & 4 & 10 & 81 & 0 & 0 & 0 & 0 & 0 & 4 \\ 7 & 7 & 0 & 0 & 81 & 0 & 2 & 0 & 3 & 0 \\ 5 & 0 & 5 & 0 & 0 & 83 & 3 & 1 & 0 & 3 \\ 41 & 0 & 1 & 2 & 0 & 3 & 53 & 0 & 0 & 0 \\ 0 & 8 & 5 & 0 & 0 & 0 & 0 & 82 & 3 & 2 \\ 0 & 42 & 1 & 3 & 0 & 0 & 0 & 4 & 48 & 2 \\ 0 & 0 & 11 & 2 & 0 & 0 & 0 & 0 & 0 & 87 \end{bmatrix}$$

[0075] 基于极限学习机的局部诊断作为证据体2,选取同样的故障样本进行测试,得到证据体2的混淆矩阵CM<sub>2</sub>:

$$[0076] \quad CM_2 = \begin{bmatrix} 78 & 1 & 2 & 0 & 0 & 2 & 14 & 0 & 3 & 0 \\ 0 & 84 & 0 & 1 & 4 & 1 & 1 & 6 & 3 & 0 \\ 1 & 2 & 73 & 0 & 0 & 7 & 2 & 8 & 1 & 6 \\ 4 & 7 & 1 & 65 & 0 & 4 & 9 & 0 & 8 & 2 \\ 2 & 11 & 1 & 2 & 69 & 6 & 6 & 0 & 3 & 0 \\ 8 & 5 & 5 & 1 & 6 & 48 & 8 & 11 & 5 & 3 \\ 11 & 0 & 0 & 8 & 1 & 2 & 72 & 3 & 2 & 1 \\ 3 & 17 & 6 & 1 & 1 & 4 & 2 & 60 & 1 & 5 \\ 0 & 12 & 2 & 2 & 2 & 3 & 3 & 5 & 69 & 2 \\ 2 & 5 & 8 & 2 & 1 & 6 & 5 & 3 & 6 & 62 \end{bmatrix}$$

[0077] 分别计算得到两个证据体对10种故障模式诊断的可靠度如表1所示。

[0078] 表1证据体E<sub>1</sub>、E<sub>2</sub>对各故障模式识别的可靠度

[0079]

证据体	$R(F_1)$	$R(F_2)$	$R(F_3)$	$R(F_4)$	$R(F_5)$	$R(F_6)$	$R(F_7)$	$R(F_8)$	$R(F_9)$	$R(F_{10})$
$E_1$	0.6000	0.5949	0.5865	0.8901	1.0000	0.9651	0.8281	0.9425	0.8000	0.7073
$E_2$	0.7156	0.5833	0.7449	0.7927	0.8214	0.5783	0.5902	0.6250	0.6832	0.7654

[0080] 现取发动机高压涡轮故障与低压涡轮故障同时发生(F<sub>10</sub>)为样本,分别采取标准D-S证据理论方法与加权D-S证据理论方法进行融合诊断。各局部诊断证据体的标准基本概率分配和加权概率分配如表2、表3所示。

[0081] 表2证据体E<sub>1</sub>、E<sub>2</sub>的标准基本概率分配

[0082]

证据体	$m_i(F_j)$									
	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$	$F_6$	$F_7$	$F_8$	$F_9$	$F_{10}$
$E_1$	0.0834	0.0834	0.2210	0.0834	0.0834	0.0845	0.0834	0.0841	0.0834	0.1098
$E_2$	0	0.1309	0.1638	0.0893	0.0038	0.0684	0.2123	0.0617	0.0259	0.2438

[0083] 表3证据体E<sub>1</sub>、E<sub>2</sub>的加权概率分配

[0084]

证据体	$Wm_i(F_j)$									
	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$	$F_6$	$F_7$	$F_8$	$F_9$	$F_{10}$
$E_1$	0.0325	0.0317	0.1611	0.1063	0.1259	0.1118	0.0856	0.1276	0.0772	0.1404
$E_2$	0	0.0538	0.1402	0.0921	0.0044	0.0274	0.1808	0.0312	0.0171	0.4530

[0085] 最后进行多证据的合成运算,将仅采用粒子滤波器和极限学习机的计算结果与采用标准D-S证据理论方法融合、加权D-S证据理论方法融合的计算结果进行对比,如图5所示。

[0086] 从表2、表3和图5可以看出,两个局部诊断证据体 $E_1$ 和 $E_2$ 的判决结论冲突严重, $E_1$ 对 $F_3$ 错误识别的可信度为0.2210,而对 $F_{10}$ 正确识别的可信度仅为0.1098; $E_2$ 对 $F_7$ 错误识别的可信度为0.2123,而对 $F_{10}$ 正确识别的可信度为0.2438。采用标准D-S证据理论方法进行融合后,融合结果对 $F_3$ 错误识别的可信度为0.3217,而对 $F_{10}$ 正确识别的可信度仅为0.2380,显然证据融合结果更支持 $F_3$ ,得到了完全错误的诊断结果。而根据诊断可靠度对各证据体进行加权处理后,证据体 $E_1$ 对 $F_3$ 错误识别的可信度下降到了0.1611,对 $F_{10}$ 正确识别的可信度升高至0.1404;证据体 $E_2$ 对 $F_7$ 错误识别的可信度下降到了0.1808,对 $F_{10}$ 正确识别的可信度升高至0.4530。采用改进的加权D-S证据理论方法进行融合后,对 $F_3$ 错误识别的可信度下降为0.1850,而对 $F_{10}$ 正确识别的可信度升高至0.5210,能够正确诊断该故障为 $F_{10}$ 。由此可见,多证据体经过加权处理后,正确识别的结论得到加强,而错误识别的结论得到削弱,从而能够提高故障融合诊断系统对故障的诊断与定位能力。

[0087] 进一步对改进的D-S证据理论融合诊断系统进行验证,随机选取不同故障模式下的样本各100组分别进行局部子系统故障诊断与融合故障诊断测试,诊断结果对比如表4所示。

[0088] 表4测试样本故障诊断识别结果对比

[0089]

诊断方法	诊断正确率 (%)										平均正确率
	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$	$F_6$	$F_7$	$F_8$	$F_9$	$F_{10}$	
PF-FL ( $E_1$ )	81	94	61	81	81	83	53	82	48	87	75.1
ELM ( $E_2$ )	78	84	73	65	69	48	72	60	59	62	67.0
标准 D-S	92	91	82	82	87	74	77	89	76	87	83.7
加权 D-S	92	88	87	88	93	72	77	89	81	89	85.6

[0090] 从表4可知,相比于单一的故障诊断方法,经过D-S证据理论融合后的发动机气路

部件故障诊断与定位的精度得到了有效提高。而改进的加权D-S证据理论融合诊断方法由于通过混淆矩阵获取了局部诊断系统对各故障模式的可靠度,对基本概率赋值进行了加权处理,降低了证据间的冲突,进一步提高了发动机气路部件故障融合诊断与定位的精度。

[0091] 上面结合说明书附图针对本发明的实施方式作了详细说明,但是本发明并不限于上述实施方式,在本领域普通技术人员所具备的知识范围内,还可以在不脱离本发明宗旨的前提下做出各种变化。




图1

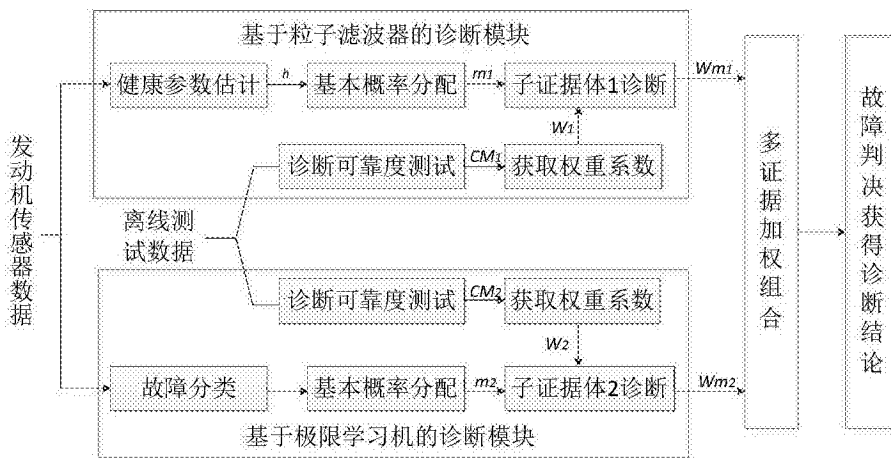


图2




图3




图4






图5