

复杂装备退化状态早期识别方法研究

邓力¹, 徐廷学¹, 肖楚琬²

(1. 海军航空工程学院 兵器科学与技术系, 山东 烟台 264001;

2. 海军航空工程学院 接改装训练大队, 山东 烟台 264001)

摘要: 针对复杂装备早期退化状态难以识别的问题, 提出一种将相关向量机 (RVM) 和 Dezert-Smarandache 理论 (DSmT) 相结合的多特征融合决策识别方法; 该方法首先分别采用时域分析法和时频域小波包变换法对装备的状态特征进行提取; 之后将状态特征向量输入 RVM 模型中完成对状态属性的判定并获得各种状态模式的基本置信度分配; 最后依据 DSmT 的 PCR6 规则对含有冲突信息的多个识别结果进行决策融合, 得到早期退化状态的最终识别结果; 在对某航空机电设备的实例应用中表明, 该方法可以有效地解决信息高冲突条件下的早期退化状态识别问题, 结果可靠准确。

关键词: 复杂装备; 性能退化; 状态识别; 相关向量机; Dezert-Smarandache 理论

Research on State Recognition Algorithm of Complicated Equipment with Early Performance Degradation

Deng Li¹, Xu Tingxue¹, Xiao Chuwan²

(1. Department of Ordnance Science and Technology, Naval Aeronautical and Astronautical University, Yantai 264001,

China; 2. Department of Modified Training Battalion, Naval Aeronautical and Astronautical University,

Yantai 264001, China)

Abstract: Aiming at the situation in which state recognition of complicated equipment with early performance degradation is hard to realize, a new fusion decision-making method based on multiple features extraction is presented, which compounds with RVM and DSmT. Firstly, a method, based on time domain analysis and wavelet packet decomposition, is used to extract the signal's feature separately; secondly, basic belief assignment function is constructed based on the output of the RVM model; lastly, PCR6 combination rule of DSmT is used to combine the different conflicting evidences and make the final decision. The application in a certain aerial electromechanical device suggests the approach is available to solve the problem of high-conflict information fusion when early vibration fault happens, and the recognition results are effective and reliable.

Keywords: complicated equipment; performance degradation; state recognition; relevance vector machine; Dezert-Smarandache theory

0 引言

在装备故障发生的早期, 及时发现故障并安排有计划的维护, 可以降低维护成本, 避免故障传播, 以免造成更大故障, 减少停机损失, 预防重大安全事故等, 因此, 早期故障及时检测与预防维护具有很大的经济与安全意义^[1-2]。

装备的故障必须有一个发展过程, 在其功能丧失之前有故障迹象或征兆^[3]。当装备在正常工作的时候, 其监测信息一般在某一常数值周围随机波动, 且较为平稳; 而当装备工作在性能退化阶段时, 监测信息就会显现出变化异常的趋势, 从而不断偏离正常态下的平稳常数值, 且偏离度会因退化程度的加剧而逐渐增加。所以, 对反映装备状态的信息进行监测来判定装备当前状态是可行的。

1 相关研究

1.1 单信息源状态识别算法

近几年用于单信息源状态识别最主要的两类算法是基于传统统计学的识别算法与统计判决法, 统计判决算法通过假设检验与概率来完成, 其主要存在的不足: 获得准确判决的门槛前提是必须给出合理的假设以及严密的数据分析; 文献^[4]运用 ANN (人工神经网络) 算法进行模式识别, 效果较为理想, 但是受样本数量的限制, ANN 算法常发生欠学习或过学习、陷入局部极小值等情况, 从而导致 ANN 算法的泛化能力较差。已有研究人员运用 SVM (支持向量机) 算法进行模式识别^[5-6], 效果要优于 ANN 算法。

但是 SVM 仍存在明显的不足^[7-9]: ①解的稀疏性只是相对, 训练样本集的增加会造成支持向量的数量线性上升; ②无法输出概率信息; ③核函数必须符合 Mercer 条件; ④需通过交叉验证等算法对正则化系数进行估计, 会产生额外的样本数据以及计算开销。

一种新型的机器学习算法 (SVM 的概率扩展) ——相关向量机 (Relevance Support Machine, RVM), 是由 Tipping 提出的与支持向量机相似的基于核函数的模式识别算法^[10]。正是该算法的提出, 使得 SVM 的不足得以有效解决; 虽然两者采用相同函数的形式, 但是用于求解核函数对应权值的算法不

收稿日期: 2015-06-26; 修回日期: 2015-09-07。

基金项目: 总装预研基金项目资助 (9140A27020212JB 14311)。

作者简介: 邓力 (1985-), 男, 江西萍乡人, 博士, 讲师, 主要从事武器装备综合保障理论与技术方向的研究。

徐廷学 (1962-), 男, 河南驻马店人, 教授, 博导。

同,这使得 RVM 大部分的权值趋于零,最终得到的模型较 SVM 更加稀疏,即模型只与部分的训练点有关。当前,RVM 已开始用于故障预测^[11]、模式识别^[12]等领域。

1.2 多信息源状态识别算法

当装备性能退化状态刚开始的时候,其状态特征通常会有以下特点:①退化状态特征信号会很微弱,从而导致状态特征呈现不确定的特性;②由于内部结构差异与传输线路的不同,微弱的退化状态特征信号通常最先在装备某个局部位置出现。所以一个传感器无法全面、准确地捕捉装备的状态信息,融合多个传感器信息成为识别退化状态的有效方式,将位于多个关键位置的传感器构造成信息网络,充分获取不同位置的测量信息,并运用信息融合技术对测量信息进行融合得到最终的识别结果。

在多信息源进行融合的过程之中,需处理的信息或数据除由随机性而造成的误差以外,通常还具有不准确、模糊、彼此不一致,甚至是部分未知、时变等特征,这些不确定性可能源于传感器的不精确性,也可能源于人为或环境等因素的干扰。

不确定性推理理论为不精确、不确定、不完善信息的处理提供了有效途径。目前不确定性推理方法有模糊理论、随机理论、粗糙集理论、贝叶斯推理理论和证据推理理论等。而证据理论以其在不确定信息的表达以及组合方面的优势受到重视。其中,DS 理论(Dempster-Shafer theory, DST)首先由 Dempster 提出通过多值映射推导出上下概率,之后由 Shafer 将其进一步完善,建立了命题与集合间一一对应的关系^[13],将命题不确定性的问题转化成集合不确定性的问题,且具有较贝叶斯推理满足条件更弱的优势,可对不知道与不确定问题进行直接表达,最终形成一整套的数学理论^[14],在故障诊断、人工智能与模式识别等方面应用广泛,并获得了丰厚的成果^[15]。但 DST 在处理高冲突证据时可能会得到与实际情况相悖的结果;同时它的前提条件要求元素是互斥的,故 DST 比较难处理连续或模糊焦元的情况。为此,Dezert 和 Smarandache 一起提出用于解决这些问题的新的证据理论——DSm 理论(Dezert-Smarandache theory, DSmT)^[16]。DSmT 的目标是建立一个统一的理论体系,即能够处理传统的问题,又能够处理实际融合中动态的、冲突的、模糊的以及不确定的较复杂的难题^[17]。

本文首先设计了复杂装备退化状态早期识别系统的框架结构,明确了识别的具体工作流程;之后筛选了状态信息的处理与特征提取方法;接下来提出了单信息源的 RVM 识别算法;最后运用 DSmT 融合算法多信息源的最终识别。应用实例表明本文提出的算法具有更高的可靠性,且识别结果与实际情况更加吻合。

2 退化状态早期识别系统

本文提出的基于 RVM 和 DSmT 复杂装备退化状态早期识别系统结构如图 1 所示。该系统主要分为信息处理与特征提取、基于 RVM 的单信息源状态识别和基于 DSmT 的状态属性决策融合等 3 个部分。

1) 信息处理与特征提取

针对装备工作时不同时间段和不同部位的工作状态信息,分别采用不同的传感器对装备工作时的数据进行采集,之后运用时域分析法和时频域分析等方法,从装备的状态信息中提取

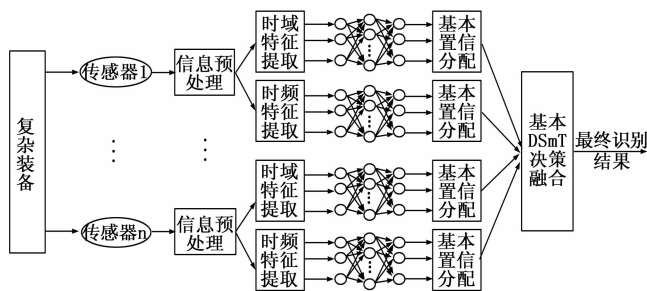


图 1 复杂装备退化状态早期识别系统结构

相关特征向量,从而得到由不同的状态特征向量构建的向量空间,并对相应的状态类型空间进行构建。

2) 基于 RVM 的单信息源状态识别:

(1) 为了构建出状态特征的向量空间与状态的类型空间之间的非线性关系,建立两个空间对应的 RVM 模型,并采用实验样本数据对该模型进行识别训练。

(2) 对已经训练好的各个 RVM,分别采用装备状态信息的测试样本数据进行测试,在测试过程中获取各 RVM 的运行时间和测试次数等信息,向 DSmT 决策融合提供重要的参数信息。

3) 基于 DSmT 的状态属性决策融合:

(1) 综合汇总各个 RVM 的不同识别结果,从而构建出 DSm 据侧融合必须的证据空间,空间的证据元素即装备同一工作状态下不同识别结果。

(2) 依据装备的状态类型构建识别空间,再依据广义基本置信分配函数 $m(\cdot)$ 获取不同状态类型可能的概率。

(3) 依据不同识别结果的基本置信度,运用 DSm 理论中合理的融合规则,得到状态类型总的概率分布,从而得出最终的识别结果。

3 信息处理与特征提取

采用传感器获取装备的状态信息之后,关键的一步就是分析处理得到的信息。运用时域分析方法与时频域小波包变换方法提取状态信息特征,形成状态信息的特征向量,并将该特征向量作为后续 RVM 的输入向量。时域分析法中的状态信息的特征向量是时域内幅值域中的参数,其对非平稳的信号比较敏感。小波包变换方法则是对装备的状态信息进行分解得到许多的独立频带,之后提取各个频带的能量作为特征向量输入 RVM 模型。时域分析方法和时频域小波包变换方法都很适合用于装备状态信息的特征提取。

3.1 时域分析

运用时域分析法得到时域特征向量元素分别为:均方根值、峰峰值、脉冲因子、峰值因子、波形因子、裕度因子和峭度因子,各向量元素的计算公式为:

$$\text{均方根值: } Z_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N z_i^2} \quad (1)$$

$$\text{峰峰值: } pp = \max_{1 \leq i \leq N} (z_i) - \min_{1 \leq i \leq N} (z_i) \quad (2)$$

$$\text{脉冲因子: } I_f = \frac{Z_{\max}}{|Z|} \quad (3)$$

$$\text{峰值因子: } C_f = \frac{Z_{\max}}{Z_{rms}} \quad (4)$$

$$\text{波形因子: } S_f = \frac{Z_{rms}}{|Z|} \quad (5)$$

$$\text{裕度因子: } CL_f = \frac{Z_{max}}{Z_r} \quad (6)$$

$$\text{峭度因子: } K_v = \sum_{i=1}^N \frac{z_i^4}{NZ_{rms}^4} \quad (7)$$

上述式中, $|Z| = \frac{1}{N} \sum_{i=1}^N |z_i|$ 为平均幅值; $Z_{max} = \max$

$\{|z_i|\}$ 为最大幅值; $Z_r = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|z_i|}\right)^2$ 为方根幅值。由以上公式计算的值为元素构成了一个 7 维时域特征向量:

$$\mathbf{T}_v = [Z_{rms}, pp, I_f, C_f, S_f, CL_f, K_v]^T$$

3.2 时频域分析

1) 小波包变换:

小波包变换作为小波分析的一种, 能够随频率的升高, 进一步将频率窗口分割细化, 同时在高频段具有较高的频率分辨与时间分辨率, 因此常被用于进行突变信号的频域分析^[18]。

小波包变换在确定小波函数之后, 将滤波系数设为: $h = \{h_n\}$, 令 $g_k = (-1)^k h_{1-k}$, 则递归函数定义如下:

$$\begin{aligned} W_{2n}(t) &= \sqrt{2} \sum h_k W_n(2t-k) \\ W_{2n+1}(t) &= \sqrt{2} \sum g_k W_n(2t-k) \end{aligned} \quad (8)$$

小波包 $\{W_n(t)\}_{n \in \mathbb{Z}}$ 由式 (8) 确定, 其中 $W_0(t)$ 为尺度函数, $W_1(t)$ 即为相应的小波函数。小波包同时将高频信号与低频信号进行分解, 从而构建成信号分解的二叉树, 各层都信号所有的频率涵盖在内, 同时频率分辨率随着层数的上升而提高。小波包变换将小波分析的二元结构改变成树式结构, 得到一组树式小波包变换如图 2 所示。




图 2 小波包变换树形结构

2) 特征提取:

小波包变换之后各尺度空间中高频的细节信号与低频的近似信号, 既能给出各频段信号的构成信息, 同时又能给出装备状态的时频局域信息。如果各分解尺度空间信号频谱的能量值能够求解出来, 就能建立状态特征信号的样本集, 供 RVM 训练与测试。下面列举了提取装备状态特征的具体过程:

(1) 状态信号的小波包变换。针对采集的装备状态信号, 利用小波包变换公式对其进行三层小波包变换, 同时得到原始小波包树形结构的最优完整树。

(2) 状态信号重构。对最优完整小波包树的底层小波包各结点进行重构, 获得重构后的 8 个小波包信号, 重构之后的信号涵盖了原始采集信号中低频至高频的各频段状态信息。

(3) 计算重构状态信号频谱的能量值。令 $S_{3i}(i = 0, 1, \dots, 7)$ 为重构后的八个小波包信号, 先对各重构信号的单边幅度

频谱 $S_{F(3,i)}(i = 0, 1, \dots, 7)$ 进行求解, 之后对各单边频谱分别取向量的二范数, 即

$$E_{3,i} = \|S_{F(3,i)}\|_2 = \sqrt{\sum_{j=1}^n |S_{F(3,i)}(j)|^2}, (i = 0, 1, \dots, 7) \quad (9)$$

式中, $|S_{F(3,i)}(j)|$ 为重构后各个小波包信号单边频谱离散点的幅值。

(4) 构建特征向量。对第三层各小波包节点频谱的能量特征值进行组合得到特征向量 $\mathbf{E} = [E_{3,0}, E_{3,1}, \dots, E_{3,7}]$, 由于频谱能量特征值有较大变化时, 会是分析过程变复杂, 因此需对数据实施归一化。即对各节点的能量值与总特征向量二范数进行除法运算, 之后得到特征向量为 $\mathbf{T}_3 = [T_{3,0}, T_{3,1}, \dots, T_{3,7}]$, 其中, $T_{3,i} = E_{3,i} / \|\mathbf{E}\|_2$ 表示结点的归一化能量特征值。

4 基于 RVM 与 DSmt 的识别算法

4.1 RVM 分类模型

在一般有监督学习过程中, 给出训练样本集包括输入向量 $\{x_n\}_{n=1}^N$ 和与之相对应的目标 $\{t_n\}_{n=1}^N$, 估计函数 $t_n = f(x_n)$, 通过训练样本集的“学习”, 建立 x_n 和 t_n 之间的关系模型, 以预测新输入向量 x_* 的未知目标 $t_* = f(x_*)$ 。其中 $t_n \in \{0, 1\}$ 为分类号。预测函数 f 可通过定义在输入空间中核函数的线性组合实现,

$$y(x; \omega) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0 \quad (10)$$

式中, $K(\cdot, \cdot)$ 为核函数, $\omega = \{\omega_i\}_{i=0}^N$ 为权重系数。对相关向量机进行训练的本质是估计出核函数最恰当的权重系数 ω , 且相关向量机能提供属于某一类 t_* 的后验概率。

对于二元分类问题, 统计学上习惯使 $y(x)$ 服从 sigmoid 函数。

$$P(t_i = 1 | \omega) = \sigma[y(x, \omega)] = \frac{1}{1 + e^{-y(x, \omega)}} \quad (11)$$

不同于回归问题, 分类不存在数据噪声。样本集的似然函数服从伯努利分布:

$$P(t | \omega) = \prod_{i=1}^N [\sigma\{y(x_i, \omega)\}]^{t_i} [1 - \sigma\{y(x_i, \omega)\}]^{1-t_i} \quad (12)$$

依据 SVM 结构风险的最小化原则可知, 若不先进行权重系数的约束, 而直接最大化式 (12) 会造成严重过拟和的现象。因此为使模型的泛化能力得到提升以实现光滑模型, RVM 为所有权重系数设定了高斯先验概率分布:

$$p(\omega | \alpha) = \prod_{i=1}^N N(\omega_i | 0, \alpha_i^{-1}) \quad (13)$$

式中, $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_N)^T$ 为超参数, 其决定了权重系数 ω 的先验分布, 并限定了权重系数的允许偏离均值程度范围。

参数 ω 和 α 的后验概率可表示为:

$$p(\omega, \alpha | t) = p(\omega | t, \alpha) p(\alpha | t) \quad (14)$$

根据贝叶斯定理 ω 的 $p(\omega | t, \alpha)$ 可进行如下分解:

$$p(\omega | t, \alpha) = \frac{p(t | \omega) p(\omega | \alpha) p(\alpha)}{p(t, \alpha)} \propto p(t | \omega) p(\omega | \alpha) \quad (15)$$

因为式中的 $p(t | \omega)$ 不是标准的高斯正态分布, 所以无法利用 RVM 用于回归与预测时采用的权重系数估计方法。只能利用 Laplace 方法通过反复迭代估计, 从而逼近 ω 最大值。采用 delta 函数进行近似的求解, 即在 $p(\omega | t, \alpha)$ 的最大值处取

ω_{MP} :

$$\omega_{MP} = \arg \max_{\omega} p(\omega | t, \alpha) = \arg \max_{\omega} \log\{p(t | \omega)p(\omega | \alpha)\} \quad (16)$$

$p(t | \omega)$ 与 $p(\omega | \alpha)$ 分布已知, 可得到:

$$\log\{p(t | \omega)p(\omega | \alpha)\} = \sum_{i=1}^N [t_i \log y_i + (1 - t_i) \log(1 - y_i)] - \frac{1}{2} \omega^T A \omega \quad (17)$$

其中: $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$; $y_i = \sigma(y(x_i, \omega))$ 。

对于和 ω 和 α 的最有估计可采用以下 3 步迭代进行。

1) 固定 α , 采用最大后验概率方法估计权重 ω 的最大值:

$$\Delta \omega = -H^{-1} g, \omega_{MP} = \omega_{MP} + \Delta \omega \quad (18)$$

其中: $g = \Phi^T(t - y) - A\omega$; $H = -(\Phi^T B \Phi + A)$; $y = [y_1, y_2, \dots, y_N]^T$ 。

$B = \text{diag}(y_1(1 - y_1), y_2(1 - y_2), \dots, y_N(1 - y_N))$;

$\Phi = (K(x, x_1), K(x, x_2), \dots, K(x, x_N))^T$

2) 求解协方差矩阵:

$$\Sigma = (-H|_{\omega_{MP}})^{-1} = (\Phi^T B \Phi + A)^{-1} \quad (19)$$

3) 更新 α_i :

$$\alpha_i^{new} = \frac{\gamma_i}{\omega_{MP}^2} \quad (20)$$

$$\gamma_i = 1 - \alpha_i \sum_{i,i} \quad (21)$$

其中: $\sum_{i,i}$ 是 Σ 中对角线上的第 i 项元素。

在给定 α 的初始值之后, 采用上述步骤进行不断迭代更新, 就能够逼近 ω_{MP} 。在迭代更新进行足够多后大多数的 α_i 会趋于无穷大, 其对应的 ω_i 则为 0。这使大部分核函数矩阵的项不会参与到预测计算中, 而其他的 α_i 会稳定趋近有限值, 与之对应的 x_i 就称之为相关向量 (Relevance Vectors, RVs), 而整个实用的计算模型称为相关向量机。

在解决多分类问题时, 可采用多个二分类器组合来实现多分类器的构造。常见方法有^[19]: 一对一法、一对多法、决策导向无环图法以及决策二叉树法等。其中一对一法 (One against one, OAO) 是指在 K 类训练样本中构造出所有可能的二分类器, 每个分类器仅在所有分类中的两类训练样本中进行训练, 最终共构建 $K(K - 1)/2$ 个分类器, 其中概率最大的那个类别被判定为最终分类。因为一对一法中构造的二分类器既简单, 同时计算量也小, 所以本文采用 OAO 方式事先多分类。

4.2 DSMT 证据理论

DSMT 定义了广义的识别框架 Θ 以及超幂集的概念, 其和 DST 最大的差别就是将其冲突信息加入框架体系内, 而 DST 的框架内只涵盖了确定与不确定信息, 却无法处理冲突信息。

定义 1: 广义识别框架。

令 $\Theta = \{\theta_1, \theta_2, \theta_3, \dots, \theta_n\}$ 由 n 个完备的元素组成的一个非空有限集合, 称 Θ 为广义识别框架。

定义 2: 超幂集。

定义超幂集 D^Θ 为由广义识别框架内的元素经过 \cup 和 \cap 运算后产生的所有组合命题集合。

定义 3: 广义基本置信分配函数。

若有广义识别框架 Θ , 且存在一组映射 $m(\cdot): D^\Theta \rightarrow [0, 1]$, 同时满足下列条件:

1) $m(\varphi) = 0, \varphi$ 为空集;

2) $\sum_{A \in D^\Theta} m(A) = 1$, 这里 $A \in D^\Theta$;

3) $0 \leq m(A) \leq 1, A \in D^\Theta$ 。

则称 $m(A)$ 为元素 A 的广义基本置信分配函数。目前关于置信的组合规则主要有经典组合规则和比例冲突再分配规则 (proportional conflict redistribution rules, PCR)。

若 $m_i(\cdot)$ 表示由多个独立且等可靠的信息源得到的广义基本置信分配函数, 则有针对性多信息源经典的组合规则 (DSmC) 如下:

$$\forall A \neq \varphi \in D^\Theta,$$

$$m_{DSmC}(A) = [m_1 \oplus \dots \oplus m_k](A) = \sum_{\substack{X_1, \dots, X_k \in D^\Theta \\ X_1 \cap \dots \cap X_k = A}} \prod_{i=1}^k m_i(X_i) \quad (22)$$

由上式可知, 当 Θ 的势增加时, D^Θ 中的元素也急剧增长, 这将耗费大量的存储空间, 也加大了经典 DSmT 组合规则的计算量。

PCR 规则是在 DSmT 基础上提出的证据组合规则。它是将冲突置信按一定比例加至组合置信上, 以便更充分地利用证据。至今已从 PCR1 发展至 PCR6 规则。其中, PCR1、PCR2 规则针对全局冲突置信实行再分配, PCR3-6 规则主要针对局部的冲突实行再分配。从 PCR1 至 PCR6, 规则的复杂度以及对冲突实行再分配的精准度都在不断提升。此外, 除 PCR1 规则, 其余规则都保证合成结果中空置信的影响中立。PCR6 为当前最为有效的规则, 其不但能获得理想的合成结果, 同时在计算量方面也具有优势。PCR6 规则定义为:

$$\forall A \neq \varphi \in D^\Theta,$$

$$m_{PCR6}(A) = m_\cap(A) + \left(\sum_{i=1}^M m_i(A)^2 \right) \cdot \sum_{\substack{\bigcap_{k=1}^{M-1} X_{\sigma_i(k)} \cap A = \varphi \\ (X_{\sigma_1(k)}, \dots, X_{\sigma_{i-1}(k)}) \in (D^\Theta)^{M-1}}} \left(\frac{\prod_{j=1}^{M-1} m_{\sigma_i(j)}(X_{\sigma_i(j)})}{m_i(A) + \sum_{j=1}^{M-1} m_{\sigma_i(j)}(X_{\sigma_i(j)})} \right) \quad (23)$$

其中, M 表示数据源个数, $m_\cap(A)$ 表示组合规则对 A 的合成信度, $X_j \in D^\Theta$ 对应证据源 $j, m_j(X_j)$ 使其相关的置信函数, σ_i 表示从 1 到 M 的数中排除 i , 即 $\sigma_i(j) = \begin{cases} j & j < i \\ j+1 & j \geq i \end{cases}$ 。

4.3 多特征 RVM-DSMT 融合决策规则

假设 k 种状态类型 A_1, A_2, \dots, A_k , 被 n 种特征提取方法获取特征向量经由 RVM 分类决策融合识别的识别框架为

$$\Theta = \{A_1, A_2, \dots, A_k\} \quad (24)$$

各种单信息源的 RVM 识别算法给各命题的置信分配函数可写成:

$$m_i(A_1, A_2, \dots, A_k, \Theta) = (q_i p_{i1}, q_i p_{i2}, \dots, q_i p_{ik}, 1 - q_i) \quad (25)$$

式中, q_i 为第 i 种特征 RVM 分类的正确率, 其值的确定可采用统计方法, 对于单信息源 RVM 分类而言, 可选择训练集样本的识别率作为该特征 RVM 分类识别正确率; p_{ij} 为第 i 种特征 RVM 分类判定样本为第 j 中状态类型识别的置信度, $j = 1, 2, \dots, k$, 其值为 RVM 分类输出概率值。

对于框架 Θ 中的任意状态类型 A_j , 多特征的 RVM 分类判定结果的 DSmT 决策规则采用 PCR6 规则。

5 应用实例

本文以某航空机电设备为研究对象。根据该型设备的特性, 该设备的电压与电流信号能较好地反映设备的性能状态, 因此, 对其不同状态下的电压与电流信号进行采集。采样频率为 6.4 kHz, 每种状态分别连续采集 24 s, 得到正常、退化与故障三组样本集, 各按顺序每组数据分割成 150 个数据段, 每段时长 0.16 s, 每段 1 024 个采样点。本应用实例数据分析所用的运行平台为 Matlab2012b, 运行环境为 Windows 7。

5.1 状态特征提取

某航空机电设备在正常状态时的电压信号波形图如图 3 所示。




图 3 正常状态电压波形图

采用时域分析法中各种指标计算公式对信号采集得到的数据进行计算, 可以得到以下指标值: $Z_{rms} = 2.706 6, pp = 1.864 9, I_f = 1.369 8, C_f = 1.368 2, S_f = 1.001 1, CL_f = 1.370 6, K_v = 1.009 6$

图 4 是采集得到的设备正常状态信号, 采用 db6 小波包进行 3 层分解的方法, 分解得到的一个时间段内每个频带中 MATLAB 仿真的信号重构图, 并计算其各频带中的能量归一化值分别为 $T_{3,0} = 0.144 3, T_{3,1} = 0.105 8, T_{3,2} = 0.125 4,$




图 4 小波包变换后各频带内重构信号图

$T_{3,3} = 0.123 9, T_{3,4} = 0.137 5, T_{3,5} = 0.130 4, T_{3,6} = 0.117 1, T_{3,7} = 0.115 3$ 。其中小波分解得到的各频带能量图如图 5 所示。




图 5 正常状态小波分解能量

5.2 基于 RVM 状态识别

为了验证本文采用的 RVM 在单信息源状态识别方面的优越性, 将 RVM 与 SVM 识别效果进行比较。本节采用电压正常和故障两组样本, 经小波包变换后获得新的 8 维频带能量向量样本序列。其中每组样本中训练样本 100 个, 测试样本 50 个。

RVM 模型中, 核函数采用最常用的高斯径向基 (RBF) 核函数, 核函数参数 σ 在 $[0.01, 5]$ 范围内通过交叉验证优化选择, 可得, 当 $\sigma = 3.75$ 时, RVM 模型识别精度最高。同理, SVM 模型中, 将 C 和 σ 在 $[1, 10]$ 范围内间隔变化计算分类精度, 得到当 $C = 100, \sigma = 6.5$ 时, 正确分类率最大, 故选择该参数为 SVM 最佳识别参数。

表 1 RVM 和 SVM 识别效果比较

训练/测试样本	识别准确率/%		向量数		测试时间/s	
	RVM	SVM	RVM	SVM	RVM	SVM
100/100	92.43	89.27	3.2	45.6	0.017 9	0.162 8
120/100	93.78	90.12	3.4	53.2	0.025 3	0.324 7
140/100	95.36	92.63	5.4	67.4	0.058 4	0.835 6
160/100	96.12	93.25	7.6	75.2	0.085 6	1.547 2
180/100	96.89	94.62	10.8	93.8	0.098 7	2.716 4
200/100	97.25	95.43	12.2	104.4	0.116 3	3.765 8

比较 RVM 与 SVM 识别效果, 样本集分别训练 5 次取均值。从表 1 可以看出, 以训练集/测试集样本数 100/100 为例, RVM 识别的准确率为 92.43%, 明显优于 SVM 识别的准确率 89.27%, RVM 平均相关向量的数量为 3.2, 远低于 SVM 平均支持向量数 45.6, RVM 识别时间为 0.017 9 s, SVM 识别时间 0.162 8 s。当训练样本数量依次增加为 120、140、160、180 和 200, 测试样本保持不变, 两种识别算法得到识别的准确率也在相应提升, 同时 RVM 识别准确率仍能略高于 SVM。当训练/测试样本的数量为 200/100 时, RVM 识别的准确率为 97.25%, 优于 SVM 的识别准确率 95.43%, RVM 平均相关向量的数量为 12.2, 远低于 SVM 平均支持向量数 104.4, SVM 识别时间增至 3.765 8 s, RVM 仍保持较低识别时间 0.116 3 s。

可见对于不同的测试和训练集, 识别时间明显小于 SVM, 识别准确率均高于 SVM 算法。同时针对于小数据集的测试样本, RVM 较 SVM 其泛化能力更优。此外, RVM 算法的解稀疏性更好, 从而致使相关向量数量远低于 SVM 支持向量的数

表 2 某型航空机电设备退化状态早期识别算例

信号源	信息特征提取	基本置信度		PCR6	DST 融合
电压	时域分析	$m(A_1)=1$	$m(A_2)=0$		
		$m(A_3)=0$			
	时频域小波分解	$m(A_1)=0.612$	$m(A_2)=0.388$	$m(A_1)=0.408$	$\forall 1 \leq i \leq 3$
电流	时域分析	$m(A_1)=0.132$	$m(A_2)=0.847$	$m(A_2)=0.547$	使得 $m(A_i)=0/0$
		$m(A_3)=0.021$		$m(A_2)=0.045$	没有意义,因此不能应用 DST
	时频域小波分解	$m(A_1)=0$	$m(A_2)=0.954$		
		$m(A_3)=0.046$			

量,且模型的结构更加简化。由于 SVM 的学习机是通过结构风险最小化的原则建立的,故只能进行归属的接受或者拒绝这样简单的判别,从而导致训练时可能会造成多个支持向量出现在界限之外,使训练具有较大误差。RVM 模型则利用贝叶斯定理输出后验概率,因此即能为检测结果是否属于该类进行量化评价,又可以为装备退化状态早期识别系统提供更直接的融合决策信息。

5.3 基于 DSmt 的融合决策状态识别

以该航空机电设备的电压与电流号作为进行融合的信号源,对其进行信号采集并采取一些初步预处理之后,进行时域与时频域的特征提取,获得的时域特征向量 T_1 和时频域特征向量 T_3 。随后将特征向量输入到训练好的 RVM 模型中,RVM 的输出经式 (25) 处理后,得到 3 种状态模式 (正常 A_1 , 退化 A_2 , 故障 A_3) 的基本置信度。最后运用 PCR6 融合规则进行最终的融合识别。表 2 列出了某航空机电设备的退化状态早期识别应用实例,为了体现本文提出算法的优越性,还同 DST 融合算法进行比较。

表 2 可以看出,由于设备刚进入性能退化阶段,状态信息比较微弱,从而致使只有电流传感器检测到较为明显的退化状态,电压传感器却检测到的退化状态和正常状态难以区分,存在信息源间信息高度冲突,这符合装备退化状态早期所具有的特征。在算例中,电流时频域输出得到的置信度值与电压时域完全冲突,信息间的冲突因子是 1,DST 融合算法无法处理此类情况;DSmt 的 PCR6 规则则可较好处理冲突信息,最终结果显示设备状态超过预定退化阈值,证明已正确检测了早期退化状态。

6 结束语

预知维修目的是降低维修的费用、并将灾难性故障风险降到最低,最终使装备发挥出其最大效能,同时减少备件(备品)的库存数量。预知维修能实现仅仅在需要的时候才对装备进行维修,从而防止装备在工作过程中出现故障,从本质上替换不适合装备的昂贵的定期维修工作,最大可能地减少装备故障的发生。

预知维修的前提是装备发生功能故障前存在退化发生点,退化状态的早期识别直接影响装备退化程度的预知,进而影响其后的维修决策。本文针对复杂装备早期性能退化状态的特征,提出了基于 RVM 和 DSmt 的识别算法,有效地解决了多信息源高冲突条件下的退化状态早期识别的问题,从而可以及时制定维修策略,减少与避免事故的发生提供了技术条件。论文的下一步将对复杂装备预知维修的另一关键技术——健康状

态预测进行研究。

参考文献:

- [1] 曾声奎, Michael G. Pecht, 吴际. 故障预测与健康管理 (PHM) 技术的现状与发展 [J]. 航空学报, 2005, 26 (5): 626-630.
- [2] 王 英. 设备状态维修系统结构与决策模型研究 [D]. 哈尔滨: 哈尔滨工业大学, 2007.
- [3] 杨景辉, 康建设. 机械设备故障规律与维修策略研究 [J]. 科学技术与工程, 2011, 7 (16): 4143-4146.
- [4] 杨 洲, 景 博, 张 劼, 等. 自动驾驶仪 PHM 系统健康评估方法研究 [J]. 仪器仪表学报, 2012, 33 (8): 1765-1772.
- [5] 冯 静, 周经伦. 基于退化失效数据的环境因子问题研究 [J]. 航空动力学报, 2010, 25 (7): 1622-1627.
- [6] 杨昌昊, 胡小建, 竺长安. 从故障树到故障贝叶斯网映射的故障诊断方法 [J]. 仪器仪表学报, 2009, 30 (7): 1481-1486.
- [7] 杨正友, 彭 涛, 李健宝, 等. 基于贝叶斯推断 LSSVM 的滚动轴承故障诊断 [J]. 电子测量与仪器学报, 2010, 24 (5): 420-424.
- [8] 代 京, 张 平, 李行善, 等. 综合运载器健康管理健康评估技术研究 [J]. 宇航学报, 2009, 30 (4): 1704-1714.
- [9] 李 中. 基于人工免疫系统的电力变压器故障诊断技术研究 [D]. 北京: 华北电力大学, 2010.
- [10] Jardine A, Lin D, Banjevic D. A review on machinery prognostic diagnostics and implementing condition-based maintenance [J]. Mechanical Systems and Signal Processing, 2005, 20 (1): 1483-1510.
- [11] 范 庚, 马登武, 邓 力, 等. 基于灰色相关向量机的故障预测模型 [J]. 系统工程与电子技术, 2012, 34 (2): 424-428.
- [12] 黄大荣, 黄丽芬. 灰色系统理论在故障预测中的应用现状及其发展趋势 [J]. 火炮发射与控制学报, 2009, 1 (3): 88-92.
- [13] Wang W Q, Uolnaraghi M F, Ismail F. Prognosis of machine health condition using neuro-fuzzy systems [J]. Mechanical Systems and Signal Processing, 2004, 18 (4): 813-831.
- [14] 段 青. 基于稀疏贝叶斯学习方法的回归与分类在电力系统中的预测研究 [D]. 济南: 山东大学, 2010.
- [15] Deh W. Time series prediction for machining errors using support vector regression [A]. Proc. of the 1st International Conference on Intelligent Networks and Intelligent Systems [C]. 2008: 27-30.
- [16] 杨颖涛, 王跃刚, 邓卫强, 等. 稀疏贝叶斯相关向量机的模拟电路故障诊断 [J]. 计算机工程, 2011, 37 (18): 7-9.
- [17] 沈 默, 廖 璞, 尹大伟. RVM 在航空发动机故障诊断中的应用研究 [J]. 计算机工程与设计, 2012, 37 (18): 220-223.
- [18] 高保禄. 大型复杂机电设备分布式故障诊断方法研究 [J]. 太原: 太原理工大学, 2010.