

基于支持向量域描述的多故障诊断动态模型

张庆^{1,2}, 徐光华^{1,2}, 王晶^{1,2}, 梁霖^{1,2}

(1. 西安交通大学机械工程学院, 710049, 西安; 2. 西安交通大学
机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 为了提高多故障诊断中对新故障类别和新故障数据的适应性, 提出了一种新的多故障诊断动态模型. 该模型采用支持向量域描述算法(SVDD)对多类故障进行单独训练, 建立独立而封闭的特征空间, 满足故障类别的动态增加需要, 并采用样本与各特征空间的相对距离进行了多故障的混合识别. 应用在线 SVDD 算法, 在已有的故障特征分布信息基础上, 通过更新操作, 学习新数据信息, 从而实现了故障模式的动态调整. 通过仿真和机械故障实例数据的检验, 表明该模型能够动态地提取多类故障的特征信息, 改善诊断学习过程的适应性.

关键词: 动态模型; 多故障诊断; 支持向量域描述

中图分类号: TH165.3 **文献标识码:** A **文章编号:** 0253-987X(2007)05-0593-05

Dynamic Multi-Fault Diagnosis Model Based on Support Vector Domain Description

Zhang Qing^{1,2}, Xu Guanghua^{1,2}, Wang Jing^{1,2}, Liang Lin^{1,2}

(1. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. State Key Laboratory for
Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To improve the adaptability of multi-fault diagnosis, a novel dynamic diagnosis model is proposed, which includes two main techniques: independent training and online adjusting for multi-fault modes. The data of every fault class are trained by support vector domain description (SVDD) to obtain the optimal enclosing feature spaces. Due to the independence of these distribution spaces, new classes can be generated facilely. The relative distances between fault data and the distribution spaces decide which class they belong to. Moreover, an online SVDD algorithm is developed to update the feature space, and the distribution information of new data is appended to the existing feature space timely. And the simulated and practical data are analyzed to verify the effectiveness of the model for dynamic multi-fault diagnosis.

Keywords: dynamic model; multi-fault diagnosis; support vector domain description

传统的故障诊断方式是通过实验或现场经验来获得故障数据, 使用统计方法设置阈值, 或者利用神经网络、隐马尔可夫过程等模型, 通过其参数或结构记忆故障特征, 继而推广应用于故障识别^[1]. 但是, 在实际的诊断过程中, 故障知识的获取是一个逐渐积累的过程, 从一次或几次的故障实验或经历中, 无法得到全面的典型故障数据, 因而也就不能建立完

备的故障模式. 另外, 设备状态是处于不断的发展变化过程中, 同一种故障在不同时刻的表现具有一定的差异, 如果故障模式固定不变, 不能随着设备的状态发展进行调整, 就会逐渐丧失其有效性. 因此, 使用具备多模式特征提取能力的动态模型, 才能够更好地满足设备的诊断要求.

动态故障诊断实际上解决的是一个多分类问

题,其动态性表现在2个方面:①故障类别可以动态添加;②每一类故障的模式能够进行动态调整,容纳新数据的特征变化.本文使用支持向量域描述(Support Vector Domain Description, SVDD)的方法,建立了封闭而紧凑的单一故障特征分布区域,结合相对距离指标,实现了多故障模式的独立学习和混合识别,并且提出SVDD在线学习算法,解决了故障模式的动态调整问题,从而构成多故障诊断的动态模型,提高了诊断技术的适应性.

1 SVDD对多类故障的诊断

传统的统计学模型只有当样本数量达到无穷大时,才能保证其理想特性,因此难以处理数量较少的故障特征数据.基于统计学习理论的支持向量机,通过协调学习机复杂性与推广性之间的矛盾,实现结构风险最小化,并且在解决小样本、非线性和高维的机器学习问题中表现出许多特有的优势^[2].作为监督型学习的两类分类器,支持向量机在处理多类问题时,一般将其转化为多个一对一或一对多问题来处理,但在训练中重复使用样本,因而无法进行动态调整.

Tax和Duin^[3]在支持向量机的基础上,提出一种新的数据描述方法——支持向量域描述(SVDD),其基本思想是建立一个封闭而紧凑的高维区域,使被描述的数据对象全部或尽可能多地包含在该区域内,而非该类对象不包含或尽可能少地进入该区域.目前,SVDD方法主要被用来对正常数据进行特征描述,以检测机器的异常状态^[4].本文使用SVDD方法建立多类故障的特征空间,根据待识别样本与各特征空间的相对距离进行类别判定.由于各类故障单独训练,新的故障类别能够自由地加入,因此不影响旧的故障模式.

1.1 SVDD算法

对于第 k 类故障样本集 $\Omega_k = \{\mathbf{x}_1^k, \mathbf{x}_2^k, \dots, \mathbf{x}_{N_k}^k\}$,其中 $\mathbf{x}_i^k \in \mathbf{R}^d$, $\mathbf{R}^d$ 表示 d 维实数集空间, N_k 为 k 类故障的样本数量,算法寻找一个能够尽可能多地包含 Ω_k 中样本的最小超球体 S_k ,用该超球体描述 k 类故障样本的高维分布区域.设该超球体的半径为 r_k ,球心为 $\mathbf{a}_k$,则求解的优化问题如下

$$\left. \begin{aligned} \min L(\mathbf{r}_k, \mathbf{a}_k, \xi_i^k) &= r_k^2 + C \sum_{i=1}^{N_k} \xi_i^k \\ \text{s. t. } \|\mathbf{x}_i^k - \mathbf{a}_k\|^2 &\leq r_k^2 + \xi_i^k \\ \xi_i^k &\geq 0, i = 1, 2, \dots, N_k \end{aligned} \right\} \quad (1)$$

式中: ξ_i^k 表示 $\mathbf{x}_i^k$ 偏离 S_k 距离的松弛因子; C 表示控制样本落在 S_k 之外程度的惩罚参数.将式(1)转化为求解如下的Lagrange极值问题

$$\begin{aligned} L(\mathbf{r}_k, \mathbf{a}_k, \xi_i^k, \alpha_i^k, \gamma_i^k) &= r_k^2 + C \sum_{i=1}^{N_k} \xi_i^k - \sum_{i=1}^{N_k} \alpha_i^k \cdot \\ &[r_k^2 + \xi_i^k - (\mathbf{x}_i^k \cdot \mathbf{x}_i^k - 2\mathbf{a}_k \cdot \mathbf{x}_i^k + \mathbf{a}_k \cdot \mathbf{a}_k)] - \sum_{i=1}^{N_k} \gamma_i^k \xi_i^k \end{aligned} \quad (2)$$

式中: $\alpha_i^k \geq 0, \gamma_i^k \geq 0$ 表示Lagrange系数.式(2)分别对 $\mathbf{r}_k, \mathbf{a}_k$ 和 ξ_i^k 求偏导数,令其等于0,将结果代回式(2),并用核函数 $K(\mathbf{x}_i^k, \mathbf{x}_j^k)$ 替代内积运算 $\mathbf{x}_i^k \cdot \mathbf{x}_j^k$,得到原始优化问题的对偶问题

$$\left. \begin{aligned} \max \sum_{i=1}^{N_k} \alpha_i^k K(\mathbf{x}_i^k, \mathbf{x}_i^k) - \sum_{i=1}^{N_k} \sum_{j=1}^{N_k} \alpha_i^k \alpha_j^k K(\mathbf{x}_i^k, \mathbf{x}_j^k) \\ \text{s. t. } \sum_{i=1}^{N_k} \alpha_i^k = 1, 0 \leq \alpha_i^k \leq C \end{aligned} \right\} \quad (3)$$

通常,选择高斯径向基函数

$$K(\mathbf{x}_i^k, \mathbf{x}_j^k) = e^{-\|\mathbf{x}_i^k - \mathbf{x}_j^k\|^2 / 2\sigma^2} \quad (4)$$

式中 σ 为核参数,则 $K(\mathbf{x}_i^k, \mathbf{x}_i^k) = 1$,原始问题最终等价于求解如下的二次规划问题

$$\left. \begin{aligned} \min \sum_{i=1}^{N_k} \sum_{j=1}^{N_k} \alpha_i^k \alpha_j^k K(\mathbf{x}_i^k, \mathbf{x}_j^k) \\ \text{s. t. } \sum_{i=1}^{N_k} \alpha_i^k = 1, 0 \leq \alpha_i^k \leq C \end{aligned} \right\} \quad (5)$$

求解式(5),得到 α_i^k ,通常只有少量 $\alpha_i^k > 0$,对应的样本点集称为支持向量集 V .超球体的中心 $\mathbf{a}_k =$

$\sum_{i=1}^{N_k} \alpha_i^k \mathbf{x}_i^k, \mathbf{r}_k$ 可由 V 中任意元素 $\mathbf{x}_s^k$ 代入下式求得

$$\begin{aligned} r_k^2 &= 1 - 2 \sum_{i=1}^{N_k} \alpha_i^k K(\mathbf{x}_i^k, \mathbf{x}_s^k) + \\ &\sum_{i=1}^{N_k} \sum_{j=1}^{N_k} \alpha_i^k \alpha_j^k K(\mathbf{x}_i^k, \mathbf{x}_j^k) \end{aligned} \quad (6)$$

1.2 多故障诊断

设共有 n 类故障通过上述的SVDD算法进行独立学习,得到 n 个封闭的超球体 $S_1, \dots, S_n$,待识别的故障样本 $\mathbf{x}$ 与 S_k 球心之间的绝对距离

$$\begin{aligned} R_{ik}^2 &= 1 - 2 \sum_{i=1}^{N_k} \alpha_i^k K(\mathbf{x}_i^k, \mathbf{x}) + \\ &\sum_{i=1}^{N_k} \sum_{j=1}^{N_k} \alpha_i^k \alpha_j^k K(\mathbf{x}_i^k, \mathbf{x}_j^k) \end{aligned} \quad (7)$$

如果 $R_{ik}^2 \leq r_k^2$,表示 $\mathbf{x}$ 落在第 k 类的故障分布区域

中;反之,若 $R_{ik}^2 > r_k^2$,则表示 $\mathbf{x}$ 位于第 k 类的故障分布区域之外。

由于各类故障单独训练,没有考虑其他类别的分布情况,因此不可避免地会造成不同类超球体的重叠,使待识别的样本同时落入多个超球体中。SVDD使用核函数将问题投影到未知的高维空间中,导致各超球体所在的特征空间相互之间没有关联关系,因此在不同特征空间中计算得到的 R_{ik}^2 ,只能判断 $\mathbf{x}$ 是否位于超球体区域中,而不能用于判断 $\mathbf{x}$ 的类归属。本文使用相对距离进行判断

$$f_k(\mathbf{x}) = \frac{R_{ik}^2}{r_k^2}, \quad k = 1, 2, \dots, n \quad (8)$$

式中: $\mathbf{x}$ 属于相对距离最小的故障类别。通过相对距离将各超球体转化为单位超球体,避免了在重合区域中半径小的超球体具有不合理的优先权,从而客观地反映出 $\mathbf{x}$ 在各故障特征空间中的分布位置。

2 在线 SVDD 算法

故障数据是从多次的实验和实践中逐步获得的,故障模式也在不断地积累更新,如果每次都把新样本和旧样本混合起来,完全抛弃已有的模式信息,重新开始训练,其浪费是显而易见的。因此,需要使用在线算法,将新样本信息动态地附加到已有模式的特征中。

文献[5]中提出了在线支持向量机的算法,用于解决分类问题,本文以此为基础,提出在线 SVDD 算法,其基本过程如下:首先使用 2 个初始样本,求解式(5)得到超球体 S_{k2} 和支持向量集 V_2 ;得到一个新的同类样本 $\mathbf{x}_i^k$ 后,再用相对距离判断新样本是否包含在超球体中,如果在超球体中,则新样本的加入不会引起超球体和支持向量集的变化,无需进行新的训练,否则说明新样本是一个支持向量,需要训练新的超球体,以容纳新样本;将 V_{i-1} 和 $\mathbf{x}_i^k$ 组成工作集 W_i ,采用式(5)对 W_i 求解得到新的超球体和支持向量集;由于 W_i 仅是样本集的一个子集,超球体的更新可能导致旧超球体内部的非支持向量点落在新的超球体之外,因此每次更新超球体之后,还需要对历史样本进行检验,将所有落在超球体外的点表示为 E_i ,在下一次训练时,将其合并入 W_{i+1} 。重复上述过程,在线处理所有样本,在已有的特征分布信息的基础上,通过更新操作来学习新的样本信息。

计算伪代码如下:

Function OnlineSVDD

{

初始样本集 $W_2 = \{\mathbf{x}_1^k, \mathbf{x}_2^k\}$, $|E_2| = 0$;

对 W_2 求解式(5),得到 S_{k2} 和 V_2 ;

for $i = 3$ to N_k

得到一个新的训练样本 $\mathbf{x}_i^k$;

if $f(\mathbf{x}_i^k) > 1$ or $|E_{i-1}| > 0$

if $f(\mathbf{x}_i^k) > 1$ and $|E_{i-1}| = 0$

$W_i = V_{i-1} \cup \mathbf{x}_i^k$;

end if

if $f(\mathbf{x}_i^k) \leq 1$ and $|E_{i-1}| > 0$

$W_i = V_{i-1} \cup E_{i-1}$;

end if

if $f(\mathbf{x}_i^k) > 1$ and $|E_{i-1}| > 0$

$W_i = V_{i-1} \cup \mathbf{x}_i^k \cup E_{i-1}$;

end if

对 W_i 求解式(5),得到 S_{ki} 和 V_i ;

$E_i = \{\mathbf{x}_j^k | f(\mathbf{x}_j^k) > 1\} \quad j = 1, \dots, i, \mathbf{x}_j^k \notin V_i$;

end if

end for

if $|E_{N_k}| > 0$

$W_{N_k} = V_{N_k} \cup E_{N_k}$;

对 W_{N_k} 求解式(5),更新 S_{kN_k} 和 V_{N_k} ;

end if

}

根据支持向量机的分解算法^[6],可知工作集和原始样本集具有相同的优化解,因此在线 SVDD 算法收敛。如果新样本已经包含在超球体中,则只需根据相对距离进行判断,省略了多余的二次规划求解运算。同时,工作集仅是原始样本集的子集,因而大大降低了二次规划求解的规模,提高了单次更新的计算效率。

3 多故障诊断动态模型

将在线 SVDD 算法应用于多类故障识别,建立了如图 1 所示的多故障诊断动态模型。对各类故障数据按顺序进行在线 SVDD 计算,学习得到当前时刻各个故障类别的特征空间——超球体,当新样本到来后,计算其在各个特征空间中的相对距离,最小相对距离对应的故障类别即为新样本的类别。将已判别的新样本加入样本集中,通过在线 SVDD 算法更新对应的特征空间,如果新样本不属于已有的故障,则建立新的故障类别,独立进行特征提取。该模型满足多故障诊断的动态性要求,符合故障特征的实际积累更新过程。




图1 多故障诊断动态模型


核参数 σ 的选择对故障特征提取效果具有较大的影响,当 σ 较大时,支持向量的数量少,超球体的体积大,不同类样本之间发生重叠的可能性较大。随着 σ 的不断减小,超球体体积也不断减小,支持向量的数目则不断增加,极端情况时是每一个支持向量都成为一个封闭区域的中心,此时的训练结果已不具备推广能力。在多故障诊断动态模型中,各类故障数据的学习过程相互独立,因此对各类样本使用独立的核参数,采用样本平均距离的一半作为初始值,当数据不断积累,样本间平均距离减小后, σ 随之进行调整,而对个别特殊样本引起样本间距变大的情况则不予考虑。由于 σ 的减小只会引起工作集样本点的增加,因此不会改变工作集和原始样本集在新的核参数条件下的等价关系,从而保证了在线SVDD算法的收敛性,同时又提高了同类故障数据在特征空间中分布的紧凑性,减少了不同类故障特征空间之间的重叠现象。

4 仿真与应用实例


4.1 二维数据集仿真

使用二维仿真数据来验证多故障诊断动态模型的有效性(见图2)。训练样本如图2a所示,共5类数据,每一类数据包含60个样本点,各类样本间相互重叠,使用在线SVDD算法分别对各类样本进行训练,取 $C=1$, σ 等于各类样本平均距离的一半。在图2b中,将训练得到的超球体边界投影到二维平面中,并标记出相应的支持向量点,可以看到各类样本


的分布特征被有效地提取出来。用图2c所示的样本进行测试,每类40个,共200个样本点,分别计算这些测试样本与5类数据特征空间的相对距离,结果如图2d所示。通过观察发现,在同类的特征空间中,样本的相对距离较小,且绝大多数小于1,反之在异类超球体中的相对距离则较大,从而有效地实现了




(a) 训练样本集



(b) 超球体边界和支持向量点



(c) 测试样本集



(d) 样本空间的相对距离

图2 多故障诊断动态模型的仿真验证

多类别的动态辨识。

4.2 应用实例

选择汽轮机轴系的故障数据^[7]进行动态特征提取,共36组样本,每组样本由8个特征值组成,分别表示测试点振动数据在频谱区间(0~0.4、0.4~0.6、0.6~1.0、1~4倍频和大于4倍频)中的最大幅值,包含不平衡、不对中、油膜涡动和动静碰摩故障。通过动态诊断模型的学习,得到各类故障样本的分布超球体,计算所有样本与各特征空间的相对距离 $f_k(\mathbf{x})$ ($k=a_1$ 为不平衡, $k=a_2$ 为不对中, $k=a_3$ 为油膜涡动, $k=a_4$ 为动静碰摩),结果如图3a所示,每种故障在自身特征空间中的相对距离均小于异类样本。对文献[8]中使用的4135型号的柴油机数据集进行分析,每次从缸盖和缸体上的3个不同采样点上分别采集振动信号,从中提取频域波形复杂度、中心频率、时域波形复杂度、非周期复杂度、方差和峭度作为特征指标,组成一组样本,共计37组样本,包括正常状态与3种故障状态。经过在线训练,得到4种状态的分布超球体,计算所有37组样本与各特征空间的 $f_k(\mathbf{x})$ (其中 $k=b_1$ 为正常, $k=b_2$ 为进气阀气门间隙过小, $k=b_3$ 为进气阀气门间隙过大, $k=b_4$ 为排气阀气门间隙过大),结果如图3b所示。设备的这4种状态在自身特征空间中的相对距离均小于异类样本,因此能够被有效地区分。

通过分析发现,利用本文提出的动态诊断模型对各类故障数据进行独立训练,建立封闭紧凑的超




图3 应用实例的故障诊断效果

球体,样本的类内间距在高维空间中被优化压缩,因此在实例数据训练结果中未出现类间重叠现象,根据相对距离指标能够有效地辨识多种故障。

5 结 论

本文建立的多故障诊断动态模型以支持向量域描述算法为基础,通过多故障模式的独立学习和混合识别,来解决故障类别动态添加的问题,并且使用在线SVDD学习算法,实现了单类故障特征空间的动态调整。经实例验证,本文建立的模型符合实际应用中的故障特征积累更新过程,因此具有广泛的应用前景。

参考文献:

- [1] 徐敏. 设备故障诊断手册[M]. 西安:西安交通大学出版社, 1998: 30-44.
- [2] John S T, Nello C. 模式分析的核方法[M]. 赵玲玲, 苏明, 曾华军, 译. 北京:机械工业出版社, 2006: 126-163.
- [3] Tax D M J, Duin R P W. Support vector domain description[J]. Pattern Recognition Letters, 1999, 20 (11-13): 1191-1199.
- [4] 李凌均, 张周锁, 何正嘉. 基于支持向量数据描述的机械故障诊断研究[J]. 西安交通大学学报, 2003, 37 (9): 910-913.
- [5] Li Lingjun, Zhang Zhousuo, He Zhengjia. Research of mechanical system fault diagnosis based on support vector data description[J]. Journal of Xi'an Jiaotong University, 2003, 37(9): 910-913.
- [6] Lau K W, Wu Q H. Online training of support vector classifier[J]. Pattern Recognition, 2003, 36(8): 1913-1920.
- [7] Lin Chih-Jen. On the convergence of the decomposition method for support vector machines[J]. IEEE Transactions on Neural Networks, 2001, 12(6): 1288-1298.
- [8] 于达仁, 胡清华, 鲍文. 融合粗糙集和模糊聚类的连续数据知识发现[J]. 中国电机工程学报, 2004, 24(6): 205-210.
- [9] Yu Daren, Hu Qinghua, Bao Wen. Combining rough set methodology and fuzzy clustering for knowledge discovery from quantitative data[J]. Proceedings of the Chinese Society for Electrical Engineering, 2004, 4 (6): 205-210.
- [10] Shen Lixiang, Francis E H, Qu Liangsheng, et al. Fault diagnosis using rough sets theory[J]. Computers in Industry, 2000, 43(1): 61-72.

(编辑 管咏梅)