

一类基于类别区分的多重故障诊断模型框架

张可^{1,2†}, 柴毅¹, 刘建环¹

(1. 重庆大学 输配电装备及系统安全与新技术国家重点实验室, 自动化学院, 重庆 400030;

2. 清华大学 自动化系, 北京 100084)

摘要: 多重故障诊断是故障诊断和容错控制技术中的重难点问题. 本文关注数据驱动故障诊断, 以基于知识的方法为基本思路, 按照故障表现及征兆的组合形式分析了多重故障和征兆之间的映射关系, 将多重故障诊断转化为一类由各个组成故障对应于征兆数据集合的类别区分问题. 在已有应用于故障诊断的分类和聚类方法的基础上, 分析了4种基于类别区分的多重故障诊断模型框架. 并讨论了其优缺点和适用的类别区分算法.

关键词: 多重故障; 故障诊断模型; 数据驱动; 模式识别; 聚类; 分类; 类别区分

中图分类号: TP183, TP277, TP306+.3 文献标识码: A

A class of category discrimination based model frameworks for multiple fault diagnosis

ZHANG Ke^{1,2†}, CHAI Yi¹, LIU Jian-huan¹

(1. State Key Laboratory of Power Transmission Equipment & System Security and New Technology,

College of Automation, Chongqing University, Chongqing 400030, China;

2. Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: Multiple fault diagnosis (MFD) is a key issue in fault diagnosis and fault tolerant control technology. This paper is concerned with data-driven based MFD. Knowledge-based approaches are taken as basic thinking ways. An analysis of relationships between multiple faults and symptoms is made according to the fault forms and combinations of fault features. By this way, MFD is resolved into a class of category discrimination problems (the multiple-fault symptom data set corresponding to each constituent fault). Existing classification and clustering based fault diagnosis methods are referred. Then, 4 kinds of category discrimination based MFD model frameworks are analyzed and proposed, and their advantages and disadvantages are separately discussed. Furthermore, a summarization of category discrimination methods that apply to the models is also given.

Key words: multiple faults; fault diagnosis models; data-driven; pattern recognition; clustering; classification; category discrimination

1 引言(Introduction)

多重故障诊断(multiple fault diagnosis, MFD)或称为复合故障诊断(composite fault diagnosis)是现代故障诊断和容错控制技术的重要难点问题和热点关注方向^[1]. 在复杂系统中, 检测到的异常工况数据中含有多个故障的情况较为常见^[2].

与独立的单一故障不同, 多重故障的发生、演化、构成较独立的单一故障更为复杂, 具有强烈的发生不确定性和组成多样性^[3], 其从组合上表现为多个独立的单一故障的组合体. 准确诊断多重故障的难度很大, 其难点主要在4个方面凸显:

1) 故障出现时, 无法直接判别其是单一故障还是多重故障;

2) 多重故障包含了哪些独立故障并非明显可知;

3) 多重故障征兆的组成和耦合方式种类复杂;

4) 多重故障发生演化和传播机理难以定量描述.

从表现形式来看, 特定的故障包含了若干个征兆, 而多重故障又包含了多个独立故障. 因此, 对多重故障的诊断必须考虑“故障-征兆”的复杂映射关系, 并满足对多个故障辨识和分离的需求. 这类故障模式识别存在多输出可能性的求解被认为是多重故障诊断的科学问题^[4].

收稿日期: 2015-06-12; 录用日期: 2015-08-21.

†通信作者. E-mail: smeta@163.com; Tel.: +86 23-65102482.

本文责任编辑: 方海涛.

国家自然科学基金项目(61203084, 61374135)资助.

Supported by National Science Foundation of China (61203084, 61374135).

但多重故障的模式与组成其的故障既不相同,也不一定存在线性关系.特别是故障体系(空间)、多重故障(子空间)、独立故障(独立子空间)、征兆(实体)之间难以使用线性关系表述^[4].受制于过大的规模和组件间的关联,能精确描述复杂系统对象的解析模型不易建立;而多重故障的标准模式样本通常无法完整采集,导致基于定性经验的诊断范围和效能受到限制.

分析近年的研究趋势,现有的多重故障诊断方法不少集中在数据驱动(data-driven)^[4-7]方面.其核心思路多为对由故障引起的系统可观测可描述的异常变化(即用于表征和区分不同故障的关键内容)进行预处理^[5-6],去除噪声和冗余等无关因素,突出故障特征信息^[6].在处理成可被诊断推理方法识别的待诊断数据(集)之后^[7],再进行推理诊断.

显然,在多重故障的机理和系统数学模型都难以获取的情况下,针对特定的对象、借助于一定的历史样本、按照一定的算法、利用故障的征兆数据直接进行推理无疑是一种可行的方法.

在数据挖掘和模式分类的研究中,将未知数据对象按照一定的规则或属性描述、区分成为若干个不同类别或组别的过程是一种典型的数据驱动方法应用.常用于提取重要数据类的模型,以及实现对不确定问题的求解.

这样的方法主要包括分类(classification)和聚类(clustering)等.广义上都能发现原始数据中的某些规律,分开这些数据并归于不同的类别(classes),或称为“簇”(clusters)、“分组”“组群”“组别”等(英语表述为“groups”,“categories”)中.这些类别通常可以被为一个确切的定义所解释(正好验证了前述“某些规律”),对应了一个确定的主题,亦能描述属于不同类数据之间的根本差异.

从本质上看,该类方法源于模式识别中的“分类器设计”、“分类识别”以及“分类决策”等.但模式分类同时还关注其它问题,“聚类分析”和“分类分析”在机制上亦存在不同.为便于表述和区别,本文将“区分并识别含有多个故障的未知模式类”作为切入点展开研究,因而将应用于故障诊断的该类方法通称为“类别区分(category discrimination)”.即,并不涉及模式分类的具体内容,而是着眼于讨论基于该类方法思路辨识和区分多重故障的诊断模型框架.

作为模式识别学科和系统安全性研究的有机结合,大量模式分类方法在故障的预处理、特征提取、辨识、分离、鉴别中广泛应用.特别是在故障诊断方面,不少有关类别区分的研究成果突出^[8-12],其核心思路多为:将已知故障模式看作独立的类,通过诊断辨识把待诊断故障归类到某个类中,对应到确定的故障模式(如早期面向故障信号区分的诊断方法).

但是,受大多数类别区分方法在分类结果上的排他性影响,当不具备多重故障样本时,若按照上述方式进行诊断,待诊断故障或只能归类到某一个故障,或无法归类成为离群点.因而,多数基于类别区分针对单一故障的诊断方法并不适宜直接应用于多重故障.

考虑到多重故障由多个独立故障组成,除开这些组成故障外,多重故障与其它独立故障具有更小的相似性或关联度;而同时组成多重故障的独立故障各自可能差异较大^[13],若能归纳出某种规律,使这些故障与其他独立故障区分开,即可为多重故障的准确诊断提供有效途径.不难发现,这样的思路与类别区分方法的原则相吻合.

目前有不少通过分析故障类别进行多重故障诊断的应用^[14-18].这些方法多基于对单一故障诊断方法的扩展,针对具体的工程问题和对象,尚未形成完整而通行的体系.笔者将在已有的研究基础上^[4],对多重故障问题和诊断进行分析,对含有多个故障的待诊断数据的诊断推理模型框架展开探究,并讨论已有成熟的类别区分方法对于该类模型的适用性.

2 多重故障及诊断描述(On multiple faults and diagnosis description)

根据故障现象和复合方式的不同,当前对多重故障定义主要集中在4种类型^[4,19-22]当中:

- 1) 系统中同时发生多个故障(并发型);
- 2) 同一模块或部件的多个继发性故障(序贯型);
- 3) 不同部位发生的多个故障,如执行器和观测器的故障复合(耦合型);
- 4) 同时具有时空特性的多个故障复合(复杂型).

这4种多重故障从机理和成因上具有较大差别,难以用通用模型描述.从多重故障的表现来看,预处理后的待诊断数据包含了若干种独立故障的征兆,较单一故障具有更多表征^[8].而且,组成多重故障的独立故障的征兆按照一定的理化规律组合起来蕴含于其中.基于此,本文将数据驱动方法为准则,考虑使用征兆或独立故障的组合来映射到多重故障上.

2.1 多重故障的征兆表示(Symptom manifestation for multiple faults)

一般地,遍历某故障体系,采集所有 n 个已知独立故障的标准模式,归纳得到 m 个征兆点,使任何故障都能使用 $\chi(1 \leq \chi \leq m)$ 个征兆表现描述.

对于征兆数值为离散值的,设 $ad(y)$ 表示第 y 个征兆是否出现,0表示“不出现”,1表示“出现”.则每种故障都能唯一对应成特定的集合:

$$\text{fault}_l = \{\text{symptom}_{ly} | ad(y) = 1\}, \quad (1)$$

其中: fault_l 为故障, symptom_{ly} 为第 l 种故障在第 y 个征兆点上的表现($l = 1, \dots, n, y = 1, \dots, m$).

在征兆数值不为二值分布时,使用 \mathbf{D} 表示整个故障体系中,每个故障对应于征兆的表现形式有

$$\mathbf{D} = [\mathbf{d}_1 \ \mathbf{d}_2 \ \mathbf{d}_3 \ \cdots \ \mathbf{d}_n]^T. \quad (2)$$

而将故障和征兆的映射关系写成如式(3)的形式:

$$\mathbf{d}_l = [f_{l1} \ f_{l2} \ f_{l3} \ \cdots \ f_{lm}], \quad (3)$$

其中: \mathbf{d}_l 表示第 l 种故障的征兆矢量, f_{ly} 表示第 l 种故障在第 y 个征兆点上的具体数值.

从故障征兆矢量上来看,多重故障无法和已知某一独立故障完全相符,但从组成上是多个独立故障的集合^[9].设 fault_x 表示某包含了多个独立故障的待诊断故障,定义 $ap(l)$ 为故障 l 在 fault_x 是否出现的二值函数,0表示“不出现”,1表示“出现”.可知

$$\text{fault}_x = \{\text{fault}_l | ap(l) = 1, l = 1, \cdots, n\}. \quad (4)$$

设构成 fault_x 的独立故障有 k 个,函数 $ar(h)$ 表示构成多重故障中独立故障的序号($1 \leq h \leq k \leq n$),有

$$\text{fault}_x = \{\text{fault}_{ar(h)} | h = 1, \cdots, k\}. \quad (5)$$

此时诊断即是确定 fault_x 对于 $\text{fault}_{ar(h)}$ 的关系(求解变量 k 和函数 $ar(h)$).若从征兆矢量入手,结合式(2)和式(3),将多重故障表示为矩阵 \mathbf{D}_x :

$$\mathbf{D}_x = [\mathbf{d}_{ar(1)} \ \mathbf{d}_{ar(2)} \ \cdots \ \mathbf{d}_{ar(k)}]^T = \begin{bmatrix} f_{ar(1),1} & f_{ar(1),2} & \cdots & f_{ar(1),m} \\ f_{ar(2),1} & f_{ar(2),2} & \cdots & f_{ar(2),m} \\ \vdots & \vdots & \ddots & \vdots \\ f_{ar(k),1} & f_{ar(k),2} & \cdots & f_{ar(k),m} \end{bmatrix}. \quad (6)$$

不失一般性,若把多重故障看作一种新的故障,其征兆结构与独立故障征兆相同,结合式(3)和式(6),用 m 个征兆构成的矢量来对应:

$$\mathbf{d}_x = [fx_1 \ fx_2 \ fx_3 \ \cdots \ fx_m], \quad (7)$$

其中 fx_y 表示某个征兆点数值表现,下标的值对应了征兆的序号.可以认为对 fault_x 的判别是对 \mathbf{d}_x 的分析.理想的情况是, fx_y 和 $f_{ar(h),y}$ 之间存在着线性关系,能够以征兆间的“相加”或“逻辑或”的形式进行组合.如式(8):

$$fx_y = \sum_h f_{ar(h),y} \text{ 或 } fx_y = \bigcup_h f_{ar(h),y}. \quad (8)$$

由于 $ar(h)$ 事先未知,考虑将 fault_x 各个征兆值的组成在整个故障体系的所有 n 个独立故障在 m 个征兆点上表示.并设存在关系式 $g_y(\cdot)$,使得式(9)成立:

$$fx_y = g_y(f_{1,y}, f_{2,y}, f_{3,y}, \cdots, f_{n,y}). \quad (9)$$

其中 $y = 1, \cdots, m$.此时, fault_x 与征兆和独立故障的关联映射即用数学方式表达出来.该思路寄望于 $g_y(\cdot)$ 能够表示出多重故障在某个征兆点上的值 fx_y 与所有构成 fault_x 的独立故障在对应征兆点 $f_{ar(h),y}$ 的关系.

2.2 征兆分析的多重故障诊断思路(A symptom analysis based way for MFD)

如式(9)中 $g_y(\cdot)$ 是线性函数,且所有的 fx_y 都能表示成这样的方式,则可将多重故障的诊断问题通过求解 $g_y(\cdot)$,使其分解为若干个组成 fault_x 的独立故障的征兆集 \mathbf{d}_l 来实现.

实际上,多重故障的复杂性往往导致 fx_y 与 f_{ly} 之间存在非线性关系,理想的可解函数 $g_y(\cdot)$ 可能完全无法得到.但二者之间若存在近似关系,可以考虑通过不确定问题求解的手段来实现 \mathbf{d}_x (即 fault_x)的诊断.

图1表现了一种理想的诊断分析思路:对 \mathbf{d}_x 解耦(对于所有已知独立故障的标准模式),将 $g_y(\cdot)$ 的求解输出对应到每种独立故障的征兆集 $\mathbf{d}_{ar(h)}$ 之上,再映射具体的独立故障,从而得到所有已知独立故障对于待诊断故障的输出列向量(即在 fault_x 是否有某独立故障存在).




图1 一种理想的数据驱动多重故障诊断思路

Fig. 1 A ideal data-driven based way for MFD

该思路中,由于事先独立故障的数量 h 和关系式 $ar(h)$ 并不可知,因此必须在整个故障样本集中遍历找出可能的组合.注意到,在不明确故障组合方式和机制的情况下,该诊断过程于图1的①②③处分别存

在不确定性问题:

1) $g_y(\cdot)$ 求解难以实现;从已有的研究成果来看,目前能够完整的实现分解耦合故障和提取故障特征的方法较少,其准确性和成熟度尚有待提升;

2) 假如上述问题能够解决, fx_y 可以被转换成 $[\bar{f}_{1,y}, \bar{f}_{2,y}, \dots, \bar{f}_{n,y}]^T$ 的形式, 但与故障样本的征兆值 f_{iy} 仍然可能存在偏差, 因而不能直接对应到故障征兆样本 d_i 上;

3) 用 \bar{d}_i 表示 $[\bar{f}_{i,1}, \bar{f}_{i,2}, \dots, \bar{f}_{i,m}]$, 设 $t_i(\cdot)$ 能表示出 d_i 与 \bar{d}_i 的关系(可以是二值化函数表示“是否”, 也可以是计算概率或置信度). 因此完成③的前提是构造出这样的关系式, 以及对 $t_i(\cdot)$ 求解;

4) 将第③步写成对 $t_i(\cdot)$ 的关系式 $q(\cdot)$, 有

$$q(t_1(\bar{d}_1), t_2(\bar{d}_2), \dots, t_n(\bar{d}_n)) = [ar(1), ar(2), \dots, ar(k)]. \quad (10)$$

但在 $t_i(\cdot)$ 的值不为二值化分布时, 必须对 $q(\cdot)$ 的求解设计专门的算法.

由此可知, 图1所示思路清晰, 也符合一般意义人们对多重故障的认识. 但是使用一般的近似线性变换或非线性逼近方法, 在实现多重故障在征兆和独立故障之间映射的统一方面存在多处难点.

2.3 多重故障诊断思路扩展(Extensions on the symptom analysis based way for MFD)

另一方面, 在实际工程中, 多重故障往往缺乏足够完备可供学习的样本. 若整个故障体系中含有 n 种独立故障, 则可能存在的多重故障有 $2^n - n - 1$ 种. 而且, 以若干个独立故障表示的多重故障模式除了仅具有数学意义之外, 按照实际建立完整的多重故障样本集并不现实, 这导致了不学习非线性变换方法在诊断结果上与实际故障存在较大的差异.

相对于多重故障样本的缺乏, 独立故障的样本较为充足. 基于此, 多重故障诊断可以被认为是将待诊断故障与已知独立故障标准模式样本逐一比对并分离的过程, 如针对某独立故障设计过滤器, 使其仅对该故障敏感, 而对其他均不敏感, 从而发现组成其的所有独立故障(图1中①也可采用这样的方式).

在不少的已有方法中, $fault_x$ 对不同独立故障的解耦和分离并不单独作为一个过程实现, 而是寄望诊断推理方法能够识别所有组成的独立故障. 若将图1中用虚线框所示过程看成黑盒, 可考虑使用其他方法来代替 $g_y(\cdot)$, $t_i(\cdot)$, $q(\cdot)$ 等关系式的求解. 此时, 输入是待诊断故障, 输出是组成该故障的独立故障组合.

对于这样的思路, 目前已有一些数据驱动方法应用于多重故障诊断. 如使用主元分析来发现故障中贡献度较高的征兆, 对应到特定的独立故障之上; 或将其作为多分类问题逐一发现具有组成可能的独立故障^[20, 23-24]. 这些方法基本上都是根据数据本身判定与哪一种(几种)已知的独立故障更相符.

因此, 充分考虑待诊断故障在构成上的不确定性, 可对多重故障诊断方法提出以下约束:

- 1) 在故障机理不明确情况下诊断具有可行性;
- 2) 不依赖于大量的多重故障样本;
- 3) 独立故障样本足够充分就能对多重故障进行辨识和判别;
- 4) 亦适用于对单一故障的诊断.

结合前述分析, 希望将组成 $fault_x$ 的独立故障和其他故障区分为不同的类别, 以实现多重故障的诊断.

3 类别区分在多重故障诊断上的应用(Category discrimination methods applied to MFD)

分类分析和聚类分析是两种重要的类别区分方法, 目的在于搜索与输入模式匹配类别, 主要用于表达数据中的知识^[25]. 二者在原理上有较为明显的区别:

分类分析通过分析由属性描述的数据样本来构造学习模型, 人工标注分类规则或标识. 在评估了模型的预测准确率之后, 将待识别的输入模式分配到各自的模式类当中. 主要的分类分析方法包括决策树归纳、贝叶斯分类、后向传播分类、基于关联规则挖掘概念的分类、 k -最近邻分类、基于案例推理、以及众多的人工智能方法等;

聚类分析不依赖于预先定义的类和训练样本, 通过算法将相似但未知的模式样本划归为一类, 而将不相似的分. 该类方法能将具有相似特征的对象聚集, 形成若干有差异的类. 类中各个元素可能并不相同, 但因为相似性而被认为是同一种类型(“最小化类间相似性, 最大化类内相似性”原则). 主要的聚类分析可以分为划分方法、层次方法、基于密度的方法、基于网格的方法、基于概率模型的方法等;

一般认为, 上述方法的区别在于有无监督: 分类分析需要有一定的学习样本(有监督), 而聚类分析主要靠启发式搜索(无监督). 实际上, 有文献认为聚类就是无监督分类或数值分类. 随着对方法的深入研究, 针对不同特定对象, 近年来出现了不少半监督的分类或聚类方法. 是否事先制定类别划分的规则, 或是否指定类标识, 已经不再是这两种方法的严格界限.

不少类别区分方法和成熟的故障诊断方法具有较强的关联性, 如基于规则的分类之于专家系统、决策树归纳分类之于故障树分析等, 其机理相似, 法则相通. 特别是在故障征兆表现存在相似度差异化的情况下, 类别区分方法更是被广泛地应用于待诊断故障与已知故障模式的区分, 以实现诊断.

图2所示是一种典型的利用类别区分的故障诊断思路: 首先将各个故障对象放置于一高维空间中, 其位置由故障征兆在不同维度上的数值确定; 通过先期的学习算法, 形成若干个由已知独立故障为中心的模式类, 此时用于类别区分的规则是对象间的空间距离(如欧几里德距离、马氏距离、曼哈顿距离); 然后将

待诊断故障输入该类别区分过程,与已知的故障样本相比较,使其能够落入其中某一个类中(如图2中的类2),该类即输出“1”、该类别所对应了故障模式即是诊断结果,而其余的类输出“0”,以形成区分。

可以看到,根据类别区分后,各类别之间的边界清晰,相互独立。从输出向量 R 中“1”的位置判定出具体的诊断结果,充分反映在类别区分过程中严格的竞争机制,即“待诊断故障是所有已知故障模式中的哪一种”。当然待诊断故障也可能出现无法归到任何一个类中,成为离群点,此时所有已知类的输出均为“0”,无法得到确切的诊断结果。

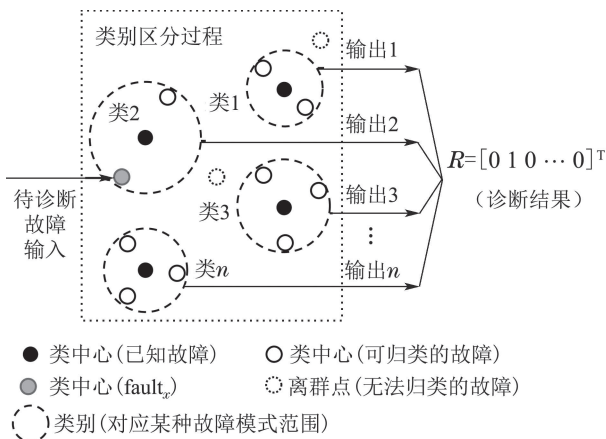


图2 典型的基于类别区分分析对独立故障进行诊断的思路
Fig. 2 A typical category discrimination analysis based way for mono-fault diagnosis

上述思路保证了诊断结果的唯一性(即 R 中“1”的个数不超过1),也正是基于这样的思想,才使类别区分方法诊断单一故障成为可能。

但在多重故障诊断中,所考量的并非是结果唯一,而是尽可能的完整。因而已有的类别区分方法在多重故障诊断中的应用需要有所针对性的改进。目前,相关应用多集中在模糊逻辑(fuzzy logic)推理、支持向量机(support vector machine, SVM)、人工神经网络(artificial neural networks, ANN)以及多方法组合。

如文[26]利用模糊诊断方程进行故障模式分类,其中采用第二代小波变换来提升分类精度,以获取有效的故障特征向量;文[27-28]采用模糊聚类方法,将样本数据模式分类,每一类代表一种故障模式,然后基于此模式分类的模式匹配过程实现多重故障诊断;

在SVM的应用方面,由于其能将低维不可分数据非线性映射至高维使其可分,常用于二分类的故障诊断:文[24, 29]将诊断中的多分类问题通过建立多个二分类器,逐步区分多重故障的组成;同时,也有不少针对多重故障诊断的改进应用,如多标签支持向量机^[15]、最小二乘支持向量机^[19]、多核支持向量机^[30]、优化支持向量机^[31]、混合支持向量机^[32]等;

从模式识别的角度来看,人工神经网络能够通过

学习已知故障样本来构建分类器,以区分待诊断故障;如学习矢量量化(learning vector quantization, LVQ)与自组织映射(self organizing map, SOM)^[21, 23]网络都具有较强的分类能力,文[34]将这两种网络结合起来将发生的多个故障归在一类当中实现诊断;此外,还包括径向基函数(radial basis function, RBF)网络^[35]、可拓神经网络^[36]等;

在方法组合方面,文[37]将ANN与SVM相结合以提升分类效果;文[38]构建了模糊神经网络分类器。对于多个影响单故障的因素同时表现得很突出时,使用模糊神经网络输出各个故障的模糊隶属度,实现边界模糊数据的有效分类;

除此之外,还有其他一些有效应用。如文[16]针对飞机液压泵同时发生的多个故障,提出了一种基于分层聚类的诊断算法,根据不同的特征提取方法构建了3个分层诊断推理引擎,通过统计平均相对能量差异(average relative power difference, ARPD),使同时发生的故障可以被分开;文[17]将Fisher判别法应用于混合故障分类,使其能够辨别出诊断前后的故障源,区分正常和故障的数据类,实现多故障的辨识和区分;文[39]将最优二叉树用于构建多故障分类器,该思路与采用SVM的方法有不少相通之处:即通过聚类分析,将多类样本聚类为两类,使多类问题转化为两类分类问题,然后使用转化后的两类样本构造该决策节点的最优分类器。

从这些方法来看,各种传统和新兴的类别区分方法都能够对多重故障诊断进行处理。但由于多重故障诊断的特殊性,这些方法也凸显了一个弱点:大部分算法将分类或聚类分析用于诊断过程中的某一个过程(如图1中的步骤③),不少原本适用于单一故障诊断的方法针对多重故障作出相应的改进的同时,缺乏完整的诊断模型。

4 基于类别区分的多重故障诊断模型(Category discrimination based models for MFD)

在本文第2部分已经讨论,图1所示的多重故障诊断思路存在的难点是通过 $g_y(\cdot)$ 的求解实现多个独立故障的分解。若考虑使用类别区分方法来替代这个处理过程,并不设置具体的函数和关系式,借助于不同类之间的差异来区分多重故障。此时,图1所示的诊断过程结构并不发生本质上的变化。

按照这样方式的理想结果是,通过分析,组成多重故障的独立故障在同一个类中,其它故障在另外的类中。如图3所示,不同 d_i 的输出表现了该独立故障是否是待诊断故障的构成故障之一。而诊断结果 R_x 则表明了整个故障体系中所有独立故障对于 $fault_x$ 的构成情况。

上述思路对每个 d_i 使用了二值化的输出来表示

$fault_x$ 的类别归属. 与图2不同, 输出向量 R_x 中“1”的数量可能会超过1, 而现有绝大多数的类别区分方法均具有排他性, 每个对象只能属于1个类. 受限于各个独立故障之间耦合方式的不同, 难以存在一个单一的阈值使其能够被无歧义的分, 使得传统的基于类别区分的故障诊断方法或将不再适用.




图 3 基于类别区分的多重故障诊断思路

Fig. 3 Category discrimination based ways for MFD

对此, 本文将结合前期的研究成果^[4,21,40-41], 对图3所示诊断推理过程进行改进, 分别就4种基于类别区分的多重故障诊断模型框架进行分析.

4.1 基于类别间交叉的多重故障诊断(Class overlapping based MFD)

文[32]认为, 从集合运算的角度使用多个独立故障的交集来描述并发故障更为合理(而非普遍认为的并集), 这样的方式可以避免对于故障辨识框架中元素必须互斥的约束. 如图4所示(设为“模型1”), 在诊断对于在归类时, 若 $fault_x$ 能落入类别间的交叉区域, 则表示产生交叉的类别所对应的故障为诊断结果.

这是一个符合逻辑的想法(尤其是体现在集合关系上), 但普遍类别区分算法并不支持带有不确定逻辑的推断.

从图4可见, 交叉多集中在数据的边界区域. 而避免类交叉、类重叠等问题一直是类别区分中的难点, 大多数成熟的类边界确定算法亦不能保证正确形成类的同时还能在多个类别之间产生交叉.

值得注意的是, 彼此交叉的类若能被归为一个类别(区分标识为“是否组成 $fault_x$ ”), 此时一些原本显然的独立分组可能并不包含标准的类, 或包含于某些类中. 虽然导致原有类别区分改变, 但这样的情况是可接受和可解释的(因为对 $fault_x$ 实现了区分).




图 4 基于类别间交叉重叠的多重故障诊断思路

Fig. 4 A class overlapping based way for MFD

4.2 基于征兆分解和类别区分的多重故障诊断(Symptom decomposition and category discrimination based MFD)

由于 $fault_x$ 中可能包含多个故障, 若基于类间交叉的诊断推理暂不可行, 考虑设计解耦器, 将待诊断故障进行预处理. 针对每一种已知独立故障 d_l 进行分解, 去除待诊断故障中的无关部分, 将所得到的故障征兆矢量分别进行归类.




图 5 基于征兆分解和类别区分的多重故障诊断思路

Fig. 5 A symptom decomposition and category discrimination based way for MFD

如图5所示(设为“模型2”), $fault_x$ 的征兆在经过分解之后得到 n 个故障征兆矢量 $p_l'(l \in [1, n])$, 经过类别区分的运算, 观测其是否能归入某个类别当中, 最终输出 $n \times n$ 的矩阵 R_x , 其中行(设序号为 $j, j \in [1, n]$)表示 p_l' 的归类结果, 列(设序号为 $i, i \in [1, n]$)表示第 i 个已知故障. 理想的结果是第 j 行中“1”只可能出

现在第 j 列上(即此时 $i = j$), R_x 中存在“1”的列就是诊断结果的组成.

该思路的机理相对朴素, 基本等同于基于类别区分的单一故障诊断方法对于 n 组待诊断故障矢量 p_l' 的应用, 其对应的每个输出矢量(设为 r_{xl})中可能最多存在1个“1”. 而 R_x 则是 n 个 r_x 的组合.

另一方面,这个方法中存在分解隔离过程,需要去除 $fault_x$ 中与已知故障 d_i 无关的量.理想情况下,如果 $fault_x$ 含有 d_i ,则分解后所得的 p_i' 等于 d_i .反之将等于值全为0的 n 维行向量(即 d_0),此时进行类别区分, p_i' 应该会成为离群点.

对于模型2的诊断推理过程,若无其他约束,目前成熟分类方法和聚类方法都能应用.但在实际的系统中,很难根据已知故障样本对待诊断故障中可能存在的故障进行解耦.因而该方法虽然合理,但核心问题在于解耦而非类别区分(即求解 $g_y(\cdot)$).

以上方法,均是以已知故障样本作为类别区分的标识或规则,诊断过程沿用了已有针对单一故障的类别区分方法来实现多重故障的诊断.这样的思路会因待诊断故障难以解耦或划分到多个类中而难以实现.

4.3 指定类标识的多重故障诊断(Class label specifying based MFD)

尝试将待诊断故障作为类别区分的辨识基准,考虑这样一个分类器(设为“模型3”):将所有已知故障样本分别输入进行归类,观测其归入以 $fault_x$ 为标识的类别(设为类 x)的情况.若能归入,则认为其为诊断结果的组成.反复输入直至所有已知故障均通过试验,最后得到的输出则是诊断结果.




图6 一种以待诊断故障为类标识的多重故障诊断思路
Fig. 6 A category discrimination way for MFD (take $fault_x$ as a class label)

常见作为类标识的参数有类中心、类边界、类中所有点的均值等.图6表现了一种以待诊断故障作为类中心的聚类方法,该方法避免了前面几种方法中的

难点,能与自己相似的故障归入类 x 中.然而多个故障的耦合极有可能导致待诊断故障征兆集与任何已知故障都不相似,或者与非组成其的故障相似度较其他故障更高,如此也难以得到准确完整的结果.

同时,该方法要求 $fault_x$ 能形成独立的类.而类标识的量化和定义若缺乏机理的支撑,将会成为一个不确定性问题.但是必须注意到,该思路已经与传统基于类别区分的方法有所差异,不以已知样本故障作为判别依据,所有的辨识均围绕待诊断故障展开.

4.4 指定多个类标识的多重故障诊断(Multiple class label specifying based MFD)

根据前文的叙述,“多重故障”可被视为由多个不同的故障组合形成的一个特殊影响域.若按照类别区分中类或簇的形成过程来理解,该区域应该对组成其的独立故障具有更高的“吸引力”.但是对于某特定故障而言,由于待诊断故障还含有其它故障模式的征兆数据,因而很难保证二者间的“相似性”.

再者,如果类别区分过程中仅存在一个确定的以待诊断故障为类标识的类别,其类边界的确定(即影响范围)也存在很大的不确定因素,常用的分类分析方法难以给出具有指导意义的规则.

改进此前面几种思路,形成如图7所示的诊断机制(设为“模型4”).其核心为将已知样本故障逐一的(即 d_i)与 $fault_x$ 进行判别,除 d_i 之外的其它已知故障也将形成各自的类别,通过无监督学习,寄望其能够区分开不同的故障模式类别.

该方法的突出点在于,已知故障之间本身存在区别,当某个已知故障为待诊断故障的组成部分时,在归类过程中,由于没有由自身作为类标识形成的类别,因此与其相似度最高应该是待诊断故障.

如图7所示,各故障独立形成以自身为类标识的类.在该过程中,类别 x 有可能与其它故障类别区分不开,或包含了除 d_i 外的组成 $fault_x$ 的其它故障.但基于“类内相似性最大”的原则,此时的归类可作为诊断结果的组成.同时,该方法要求形成以 $fault_x$ 为中心的类,无法避免“模型3”中的问题.




图7 以待诊断故障和独立故障同时形成独立类别的多重故障诊断思路

Fig. 7 A category discrimination based way for MFD ($fault_x$ and known mono-faults can be formed several independent classes)

另外,也有可能组成 fault_x 的故障不区分至类别 x 中,这样的结果是符合实际的.因为在两个不同故障无法形成两个独立类别时,本就说明故障间相似性较大,并不违背“类外相似性最小”的原则.此时就必须调整算法,使该类别能归入到类别 x 中.从此处也可看出多重故障诊断是一种探索式的分析过程.

同时,借鉴模型2和模型3所示思路,还可以对本方法进行改进,如图8所示.

假设某个故障 d_i 恰好是 fault_x 的组成部分,但却成为了离群点.这有可能是因为多重故障所包含的其它故障征兆过多,而降低了与 d_i 的相似性.鉴于此,将 fault_x 解耦将能确保对于每种故障的针对性.

该思路综合了上述所有方法的优势,既保留了输入向量之间的差异,也保留了在类别区分过程中的多个已知独立故障归为一类的不确定性.但是,该方法仍然无法避免解耦困难的问题.




图 8 一种基于征兆分解和类别区分的多重故障诊断思路(以待诊断故障为类中心)

Fig. 8 A way of thinking for MFD by category discrimination and feature decomposition (take fault_x as a class label)

4.5 适用的类别区分方法分析 (Analysis on category discrimination methods that apply to MFD)

由此,通过对“故障—征兆”映射关系的探究,提出的基于类别区分的诊断模型从结构上满足多重故障诊断的需求.同时,这4种模型也对适用于多重故障诊断的类别区分方法提出了要求:

1) 模型1要求同一个对象能划分到多个类中,这是一般的类别区分方法难以实现的.但是,对于“一个数据对象属于多个簇”的问题可以制定出多个类标识,使用基于概率模型的聚类方法和模糊聚类解决.

在模糊聚类^[25](又称“软聚类”, soft clustering)中,聚类过程被描述为带有约束的优化问题:每一个数据记录可以不属于一个分组,使用隶属度来表示某个对象属于不同簇的程度;而在基于概率模型的方法中,通过概率密度函数来找出不同的概率簇.

按照这样的方法,针对当前的待诊断故障设定目标函数,利用类如可能性模糊 c 均值聚类(possibilistic fuzzy c -means clustering, PFCM)方法,计算多重故障对于每种独立故障的可能性.但是,这两种方法都需要使用期望最大算法(expectation-maximization, EM)多次迭代来使簇内的对象相似度最大化,而该算法通常可能收敛不到最优解,同时也存在着计算开销过大的问题.

2) 模型2的难点在于对待诊断故障的解耦.之后基于类别区分的诊断推理可使用较为成熟的方法.

考虑到分解后的征兆数据与对应的已知故障存在

偏差,使用带有联想学习机制的人工智能方法能逼近真实数据.如SOM, LVQ, RBF等神经网络、概率神经网络(probabilistic neural networks, PNN)、自适应共振理论(adaptive resonance theory, ART)、以及基于案例的推理(case-based reasoning, CBR)等.这些方法通常需要大量的已知故障样本进行训练.

3) 模型3要求以待诊断故障形成一个模式类,所有组成待诊断故障的独立故障归类于其中,其余故障分配到另外的类中.

这可以被看作是一个二分类问题,使用SVM或具有较好的效果.但SVM的优势在于处理“线性可分”的数据,在线性不可分时需要将数据映射到较高维空间中,创建能够发现非线性超平面的算法.而对于构成多重故障的若干个独立故障,在映射到故障空间中位置事先未知,基本无法保证线性可分的情况.若将其映射到高维空间中,会导致训练和检验速度降低.同时,按已有的核函数选择方法,也不能确保能发现可以界定是否是组成多重故障的非线性超曲面.

另一方面,该模型需要以待诊断故障为依据形成类,且在划分类的过程中,待诊断故障的类标识地位不能发生变化.

在聚类方法中,以空间距离作为判别依据的划分方法能够基于形心形成类(簇),如谱聚类(spectral clustering, SC), k -means、 k -modes和相关改进等;基于相似度的划分方法(如affinity propagation, AP聚类)能够通过计算类中各个点之间的相似度确定划分类的判别依据;围绕中心点划分(partitioning around

medoids, PAM)可以事先定义中心点.但是,这些方法在划分过程中需要更新簇(类)中心,即随时可能改变标识,因而难以达到该模型的应用要求.

具有约束的聚类能通过对簇的属性进行人为要求,达到预想效果.因此,可以通过设定与待诊断故障相关的约束条件,在类别过程中使用约束本身的一致程度来评估质量并进行优化改进.这是一种基于半监督学习聚类的故障诊断方法.

4) 模型4较同于模型3,要求以待诊断故障形成类,可采用类别区分方法与之类似.但由于有其它样本故障的参与,不再是二分类的问题.

按照该模型的思路,事先指定类的最大数量.对于本文所述的故障体系,定义类的数量为 n (包括了 $n-1$ 个已知故障样本和1个待诊断故障),理想情况是每种故障样本和待诊断故障都能各自形成类,而进行判别的独立故障至多划分到1个类中,或成为离群点.

不可避免的是,多个故障或归于一类,但这也说明了这些故障之间存在相似性或关联性.而在多重故障诊断当中,这样的诊断结果符合预期(如“故障覆盖”在没有更多的约束条件下被认为合理).

因此可使用基于拟生物进化(如遗传算法)的分类方法来对适合的最优分类进行演化求出近似解;亦可以采用概率层次聚类,使用概率模型来合并原本使用距离度量不能归于一类的数据对象,这对基于距离区分类别的故障诊断方法是一个有效的优化思路.

5) 其他需要就类别区分考虑的因素还包括:故障模式类的形状未知,很大可能会是非凸面形状;故障征兆维数可能非常高;故障多样化导致的类别区分质量评估方法等.

除此之外,在确定了用于多重故障诊断推理的类别区分算法之后,上述模型尚存在必须重视的问题:

1) 由于故障体系的多样性,如何保证各已知独立故障能形成独立的类别;

2) 在故障对象机理模型不确定的情况下,类别的范围和边界如何确定;

3) 在征兆耦合非线性特征明显时,待诊断故障的征兆如何分解;

4) 多种类别区分方法融合优化,所得的效果和适应性提升能力如何和多重故障诊断相结合;

5) 未考虑模型的时间复杂度.

5 结语(Summary)

本文关注数据驱动的故障诊断.分析了多重故障诊断存在的难点、以及已有方法在多重故障诊断中的局限性.讨论了多重故障诊断和单一故障诊断关系,描述了多重故障模式的表示以及与征兆间的映射.以典型的基于类别区分的故障诊断思路出发,提出并分析了一类基于类别区分的多重故障诊断模型框架,并

探讨了对应方法的适用性.

在本文分析的4种模型中,充分的应用了类别区分析的分析的竞争机制,寻找足够相似的已知故障,排除足够不相似的故障,符合故障诊断“检测、鉴别、区分、判断”的基本原则.若能对其中的具体算法展开研究,验证其有效性,规避不足,将有望将其转化为实际方法并投入应用,也是下一步需要进行的重要工作.

参考文献(References):

- [1] ODINTSOVA N, RISH I, MA, S. Multi-fault diagnosis in dynamic systems [C] // *Proceedings of the 9th IFIP/IEEE International Symposium on Integrated Network Management*. Nice: IEEE, 2005, (Poster-CD).
- [2] GUI Weihua, LIU Xiaoying. Fault diagnosis technologies based on artificial intelligence for complex process [J]. *Control Engineering of China*, 2002, 9(4): 1-6.
(桂卫华, 刘晓颖. 基于人工智能方法的复杂过程故障诊断技术 [J]. 控制工程, 2002, 9(4): 1-6.)
- [3] SCHERTZ D R, METZE G. On the design of multiple fault diagnosable networks [J]. *IEEE Transaction on Computers*, 1971, 20(11): 1361-1364.
- [4] ZHANG Ke, ZHOU Donghua, CHAI Yi. Survey on multiple fault diagnosis methods [J]. *Control Theory & Applications*, 2015, 32(9): 1143-1157.
(张可, 周东华, 柴毅. 复合故障诊断技术综述 [J]. 控制理论与应用, 2015, 32(9): 1143-1157.)
- [5] HOU Zhongsheng, XU Jianxin. On data-driven control theory: the state of the art and perspective [J]. *Acta Automatica Sinica*, 2009, 35(6): 650-667.
(侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望 [J]. 自动化学报, 2009, 35(6): 650-667.)
- [6] ZHOU Donghua, YE Yinzong. *Modern Fault Diagnosis and Fault-tolerant Control* [M]. Beijing: Tsinghua University Press, 2000.
(周东华, 叶银忠. 现代故障诊断与容错控制 [M]. 北京: 清华大学出版社, 2000.)
- [7] WANG Hong, CHAI Tianyou, DING Jinliang, et al. Data driven fault diagnosis and fault tolerant control: some advances and possible new directions [J]. *Acta Automatica Sinica*, 2009, 35(6): 739-747.
(王宏, 柴天佑, 丁进良, 等. 数据驱动的故障诊断与容错控制: 进展与可能的方向 [J]. 自动化学报, 2009, 35(6): 739-747.)
- [8] AL-RAHEEM K F, ROY A, RAMACHANDRAN K P, et al. Application of the Laplace wavelet combined with ANN for rolling bearing fault diagnosis [J]. *Journal of Vibration and Acoustics*, 2008, 130(5): 60-68.
- [9] THUKARAM D, KHINCHA H P, VIJAYNARASIMHA H P. Artificial neural network and support vector machine approach for locating faults in radial distribution systems [J]. *IEEE Transactions on Power Delivery*, 2005, 20(2): 710-721.
- [10] BO Cuimei, BAI Yangjin, YANG Hairong, et al. Multi-section classification improving integrated fault diagnosis method based on independent component analysis and support-vector-machines [J]. *Control Theory & Applications*, 2012, 29(2): 229-234.
(薄翠梅, 柏杨进, 杨海荣, 等. 多切面分类改进独立成份与支持向量机集成故障诊断方法 [J]. 控制理论与应用, 2012, 29(2): 229-234.)
- [11] WU Yuxiang, ZHANG Jing, WANG Cong. Fault diagnosis of cracked rotor systems based on radial basis function neural networks [J]. *Control Theory & Applications*, 2014, 31(8): 1061-1068.
(吴玉香, 张景, 王聪. 基于径向基函数神经网络的转子系统裂纹故障诊断 [J]. 控制理论与应用, 2014, 31(8): 1061-1068.)

- [12] LIU Kaidi, CAO Qingkui, PANG Yanjun. A method of fault diagnosis based on unascertained set [J]. *Acta Automatica Sinica*, 2004, 30(5): 747 – 756.
(刘开第, 曹庆奎, 庞彦军. 基于未确知集合的故障诊断方法 [J]. 自动化学报, 2004, 30(5): 747 – 756.)
- [13] SINGH S, KODALI A, CHOI K, et al. Dynamic multiple fault diagnosis: Mathematical formulations and solution techniques [J]. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 2009, 39(1): 160 – 176.
- [14] ZHU D, BAI J, YANG S X. A multi-fault diagnosis method for sensor systems based on principle component analysis [J]. *Sensors*, 2010, 10(1): 241 – 253.
- [15] POOYAN N, SHAHBAZIAN M, SALAHSHOOR K, et al. Simultaneous fault diagnosis using multi class support vector machine in a dew point process [J]. *Journal of Natural Gas Science and Engineering*, 2015, 23(3): 373 – 379.
- [16] DU Z, WANG S, ZHANG H. Layered clustering multi-fault diagnosis for hydraulic piston pump [J]. *Mechanical Systems and Signal Processing*, 2013, 36(2): 487 – 504.
- [17] DU Z, JIN X. Multiple faults diagnosis for sensors in air handling unit using Fisher discriminant analysis [J]. *Energy Conversion and Management*, 2008, 49(12): 3654 – 3665.
- [18] PECINA-SANCHEZ J A, CAMPOS-DELGADO D U, ESPINOZA-TREJO D R. Multiple fault diagnosis in variable speed drives through current measurements [C] // *The 8th International Conference on Electrical Engineering Computing Science and Automatic Control (CCE)*. Merida City: IEEE, 2011, 10: 1 – 6.
- [19] HU Changhua, CAI Yanning, ZHANG Qi. Simultaneous fault diagnosis based on multi-regression LSSVM [J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2009, 37(SI): 1 – 5.
(胡昌华, 蔡艳宁, 张琪. 基于多重回归LSSVM的并发故障诊断 [J]. 华中科技大学学报(自然科学版), 2009, 37(SI): 1 – 5.)
- [20] ZHOU Funa, WEN Chenglin, TANG Tianhao, et al. DCA based multiple faults diagnosis method [J]. *Acta Automatica Sinica*, 2009, 35(7): 971 – 982.
(周福娜, 文成林, 汤天浩, 等. 基于指定元分析的多故障诊断方法 [J]. 自动化学报, 2009, 35(7): 971 – 982.)
- [21] ZHANG K, CHAI Y, YANG S X. Self-organizing feature map for cluster analysis in multi-disease diagnosis [J]. *Expert System with Applications*. 2010, 37(9): 6359 – 6367.
- [22] HUANG Yifeng, JING Bo, LUO Binghai, et al. Sequential multiple fault diagnosis strategy based on Rollout algorithm [J]. *Control and Decision*, 2015, 30(3): 572 – 576.
(黄以锋, 景博, 罗炳海, 等. 基于Rollout算法的序贯多故障诊断策略 [J]. 控制与决策, 2015, 30(3): 572 – 576.)
- [23] GHARAVIAN M H, GANJ F A, OHADI A R, et al. Comparison of FDA-based and PCA-based features in fault diagnosis of automobile gearboxes [J]. *Neurocomputing*, 2013, 121(12): 150 – 159.
- [24] SU Z, TANG B, LIU Z, et al. Multi-fault diagnosis for rotating machinery based on orthogonal supervised linear local tangent space alignment and least square support vector machine [J]. *Neurocomputing*, 2015, 157(1): 208 – 222.
- [25] HAN J, KAMBER M, PEI J. *Data Mining: Concepts and Techniques* [M]. Third Edition. San Francisco: Morgan Kaufmann, 2011.
- [26] RUI Z, WEN B, NING L, et al. Mechanical equipment fault diagnosis based on redundant second generation wavelet packet transform [J]. *Digital Signal Processing*, 2010, 20(1): 276 – 288.
- [27] LI Tianen, HE Zhen. Kernel-based fuzzy clustering algorithm for multi-faults diagnosis of complex products [J]. *Systems Engineering Theory and Practice*, 2013, 33(1): 181 – 186.
(李天恩, 何桢. 复杂产品多故障诊断中的核模糊聚类方法 [J]. 系统工程理论与实践, 2013, 33(1): 181 – 186.)
- [28] ISAZA C V, SARMIENTO H O, KEMPOWSKY-HAMON T, et al. Situation prediction based on fuzzy clustering for industrial complex processes [J]. *Information Sciences*, 2014, 279(9): 785 – 804.
- [29] BATISTA L, BADRI B, SABOURIN R, et al. A classifier fusion system for bearing fault diagnosis [J]. *Expert Systems with Applications*, 2013, 40(17): 6788 – 6797.
- [30] CHEN F, TANG B, SONG T, et al. Multi-fault diagnosis study on roller bearing based on multi-kernel support vector machine with chaotic particle swarm optimization [J]. *Measurement*, 2014, 47(1): 576 – 590.
- [31] ZHANG X, ZHOU J. Multi-fault diagnosis for rolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines [J]. *Mechanical Systems and Signal Processing*, 2013, 41(1/2): 127 – 140.
- [32] GAO G, ZHANG Y, ZHU Y, et al. Hybrid support vector machines-based multi-fault classification [J]. *Journal of China University of Mining and Technology*, 2007, 17(2): 246 – 250.
- [33] GERMEN E, BAARAN M, FIDAN M. Sound based induction motor fault diagnosis using Kohonen self-organizing map [J]. *Mechanical Systems and Signal Processing*, 2014, 46(1): 45 – 48.
- [34] XU Chongbin, ZHAO Zhiwen, ZHENG Huifang. Multi-fault diagnosis for wide-deviation analog circuits based on ELVQ Algorithm [J]. *Journal of Electronics and Information Technology*, 2011, 33(6): 1520 – 1524.
(徐崇斌, 赵志文, 郑慧芳. ELVQ算法实现宽参数偏移的多故障电路诊断 [J]. 电子与信息学报, 2011, 33(6): 1520 – 1524.)
- [35] ZHANG K, LI Y, SCARF P, et al. Feature selection for high-dimensional machinery fault diagnosis data using multiple models and radial basis function networks [J]. *Neurocomputing*, 2011, 74(17): 2941 – 2952.
- [36] WEN Tianzhu, XU Aiqiang, CHENG Gong. Multi-fault diagnosis method based on improved ENN2 clustering algorithm [J]. *Control and Decision*, 2015, 30(6): 1021 – 1026.
(文天柱, 许爱强, 程恭. 基于改进ENN2聚类算法的多故障诊断方法 [J]. 控制与决策, 2015, 30(6): 1021 – 1026.)
- [37] KANKAR P K, SHARMA S C, HARSH S P. Fault diagnosis of rolling element bearing using cyclic autocorrelation and wavelet transform [J]. *Neurocomputing*, 2013, 110(7): 9 – 17.
- [38] YAN Pengcheng, LIAN Guangyao, LIU Xiaoqin, et al. Research on sequential multiple fault diagnosis method based on multiple fault ambiguity group [J]. *Computer Measurement and Control*, 2012, 20(1): 34 – 37.
(闫鹏程, 连光耀, 刘晓芹, 等. 基于多故障模糊组的序贯多故障诊断方法 [J]. 计算机测量与控制, 2012, 20(1): 34 – 37.)
- [39] ZHU Xuedong, HU Ping. The design of multi-fault classification based on Huffman binary tree [J]. *Journal of Beijing Union University (Natural Sciences)*, 2009, 23(2): 26 – 29.
(朱学冬, 胡平. 基于最优二叉树的多故障分类器的设计 [J]. 北京联合大学学报(自然科学版), 2009, 23(2): 26 – 29.)
- [40] ZHANG K. *Research and applications on intelligent multi-fault diagnosis methods based on sympotom analysis* [D]. Chongqing: Chongqing University, 2010.
- [41] ZHANG K, CHAI Y, LIU J, et al. Analysis of class group distinguishing based conceptual models for multiple fault diagnosis [C] // *Proceedings of the 34th Chinese Control Conference*. Hangzhou: IEEE, 2015, 7: 6397 – 6402.

作者简介:

张可 (1979–), 男, 博士, 副教授, 硕士生导师, 主要研究方向为智能控制和故障诊断、先进智能信息系统等, E-mail: smeta@163.com;

柴毅 (1962–), 男, 博士, 教授, 博士生导师, 研究方向为信息融合、系统检测、故障诊断等, E-mail: chaiyi@cqu.edu.cn;

刘建环 (1990–), 男, 硕士研究生, 研究方向为模式分类和故障诊断等, E-mail: jianhuan0622@csu.edu.cn.