

## 基于 $K$ 近邻证据融合的故障诊断方法

侯平智<sup>1</sup>, 张 明<sup>1</sup>, 徐晓滨<sup>1†</sup>, 黄大荣<sup>2</sup>

(1. 杭州电子科技大学 自动化学院, 杭州 310018; 2. 重庆交通大学 信息科学与工程学院, 重庆 400074)

**摘 要:** 为了兼顾数据建模的准确性和诊断的实时性, 提出一种  $K$  近邻诊断证据融合新方法. 利用故障特征的历史样本构建随机模糊变量 (RFV) 形式的故障样板模式, 由 KNN 算法获取测试样本的  $K$  个近邻历史样本, 并定义它们的 RFV 待检模式; 经样板和待检模式的匹配获取  $K$  个诊断证据, 再将各特征的  $K$  个诊断证据融合, 并作出故障决策; 使用 RFV 实现对故障数据的精准建模, 利用  $K$  个历史样本丰富诊断信息, 并增加诊断的时效性. 诊断效果在电机转子试验台上得到了验证.

**关键词:** 故障诊断; 工业报警器系统; 证据理论;  $K$  近邻; 随机模糊变量

**中图分类号:** TP391

**文献标志码:** A

## Fault diagnosis based on KNN evidence fusion

HOU Ping-zhi<sup>1</sup>, ZHANG Ming<sup>1</sup>, XU Xiao-bin<sup>1†</sup>, HUANG Da-rong<sup>2</sup>

(1. School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China; 2. School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

**Abstract:** A fault diagnosis method based on KNN evidence fusion is presented to keep a balance between modeling accuracy of fault feature data and instantaneity of diagnosis decision making. For each fault feature(symptom), its historical sample data are used to model fault template patterns(FTP) with the form of random-fuzzy variable(RFV), the KNN algorithm is used to find out  $K$  historical samples nearest to a testing sample and the RFV-type fault testing patterns(TPs) of the  $K$  samples are presented to describe the testing sample. The matching degree between FTP and TP can be calculated to generate the  $K$  pieces of diagnosis evidence, and then all evidence coming from the different fault features can be fused and diagnosis decision can be made based on the fused result. In this method, the fine modeling can be realized by using the RFV, and meanwhile, the diagnosis information of the single testing sample can be enriched by adding the  $K$  historical samples, and the instantaneity of diagnosis can be improved. Finally, in diagnosis experiments on a rotor test bed, the effectiveness of the proposed method is verified.

**Keywords:** fault diagnosis; industrial alarm systems; evidence theory; KNN; random-fuzzy variable

## 0 引 言

故障诊断作为提升系统稳定性和减少事故风险的重要方法, 是实现故障报警溯源和报警消除、提升工业设备的自诊断与自纠错能力的主要途径. 然而, 基于单传感器的监控诊断技术获得的信息, 已无法足够可靠地用于大型复杂设备的诊断. 随着传感器技术的发展以及计算机存储和计算能力的提高, 大量的监测数据可以通过安装在设备上的多传感器系统获取、存储和处理. 然而在测量过程中, 因为环境的影响以及仪器自身的系统误差, 如传感器的精度或 A/D 转换器的量化误差, 导致监测数据总是具备不确定性

的特点. 不确定性的影响因素主要来自两个方面: 一是测量仪器处于工作状态时所受到的随机噪声干扰, 二是传感器自身及其后续信号调理电路的系统性误差. 因此, 针对多源不确定性信息的有效诊断推理是现在面临的新挑战<sup>[1]</sup>.

基于证据理论的信息融合故障诊断方法是将多个传感器的互补和冗余信息进行融合, 以减小决策不确定性, 与基于单传感器的方法相比, 它能够有效地提高故障诊断的精度和可靠性<sup>[1-5]</sup>. 一般而言, 此类方法的实现步骤为<sup>[2-3]</sup>: 确定辨识框架(由全部故障类型构成的集合); 对故障样板模式和待检模式进行建

收稿日期: 2016-09-20; 修回日期: 2017-01-03.

基金项目: 国家自然科学基金项目(61433001, 61374123, 61573076, 61573275); 浙江省公益性技术应用研究计划项目(2016C31071); 重庆市高等学校优秀人才支持计划项目(2014-18).

作者简介: 侯平智(1968—), 男, 教授, 从事基于数据驱动的状态监控与故障诊断等研究; 徐晓滨(1980—), 男, 教授, 从事智能信息融合与复杂系统可靠性评估、故障诊断与预测等研究.

†通讯作者. E-mail: xuxiaobin1980@163.com

模;匹配故障样板模式和待检模式以获取基本概率赋值(BBA),即可用于诊断的证据;利用 Dempster 证据组合规则融合 BBA,再结合融合结果按照决策规则诊断故障.其中,故障样板模式和待检模式都是根据测量仪器所采集的监测数据构建的<sup>[2]</sup>.一般数据测量过程中的不确定性是难以建模和估计的,进而导致从数据中提取的故障特征不准确,并且致使所获得的 BBA 不可靠,这将造成最终融合结果的可信性无法得以保证.文献[2]通过高斯型模糊隶属度函数来表征故障特征样板模式和待检模式,然后利用模糊集的随机集表示随机集似然测度,计算待检模式和不同故障类型样板模式的匹配度,并从中获取 BBA.但是,此类诊断证据生成方法有两个缺点:一是故障数据建模准确性问题.利用隶属度描述数据变化规律时,没有充分考虑“随机噪声干扰”和“系统性误差”这两个不确定性因素的区别,所以这种简单模型难以捕捉到数据中更为精细的故障信息.二是诊断的实时性问题.为了准确地描述监测数据的变化规律,需要连续采集多个时刻的在线测试样本,并利用获取的测试样本集构造高斯隶属度函数型的待检模式.虽然样本集比单个样本更能够反映数据变化的趋势,但是它是牺牲实时性为代价的.例如用连续 20 次采样(采样频率为 1s/次)的数据构造待检模式,并将其输入到诊断算法中,则 20s 才能给出一次诊断结果,这在许多需要在线监测的应用场合显然不能满足实时诊断的要求.

对于故障数据建模准确性问题,在文献[6]中,由系统误差产生的不确定性使用模糊变量来表示,同时,由噪声引起的不确定性使用随机变量来描述,并将它们相结合提出随机模糊变量(RFV).通过 RFV 可以合理地表示测量不确定性中不同的影响因素(随机性和系统性误差),非常全面和自然地描述测量所具有的不确定性<sup>[7]</sup>;另外,对于诊断实时性问题, $K$ 近邻算法(KNN)给出了一种可行的思路,利用与测试样本最近的  $K$  个历史样本(带故障标记)来判断该测试样本指向的故障类型,亦即哪个故障类型的样本数量最多,则测试样本也标记为该类型故障.此时,相当于利用一个样本集(由  $K$  个历史样本组成)来代替单一测试样本进行分类决策,变相地增加了与测试样本相关的大量历史样本信息用于诊断,这样可以提升诊断的实时性.但是当有多个故障类型的标记样本数量相同时,这种“少数服从多数”的判决规则失效.为了解决该问题,文献[8]提出将  $K$  个历史样本转

化为  $K$  个证据,利用证据的融合在一定程度上减少了判决失效的情况.

为了同时兼顾数据建模准确性和诊断实时性,本文提出一种新的  $K$  近邻诊断证据融合方法.对于每种故障特征(征兆),利用它的历史样本数据构建 RFV 形式的故障样板模式,基于 KNN 算法获得离测试样本最近的  $K$  个历史样本,并定义这  $K$  个样本的 RFV 型待检模式.将待检 RFV 与样板 RFV 匹配以获取  $K$  个诊断证据,然后融合不同故障特征的  $K$  个诊断证据,基于融合结果再进行故障决策.最后,通过在电机柔性转子上的故障诊断试验,验证了所提方法的诊断效果普遍优于传统的 KNN 方法<sup>[9]</sup>、模糊匹配证据融合方法<sup>[2]</sup>、 $\alpha$ 截集匹配证据融合方法<sup>[7]</sup>以及 KNN 和证据融合相结合的方法<sup>[8]</sup>.

## 1 相关理论基础

### 1.1 Dempster-Shafer 证据理论

在证据理论中,首先确定全体研究对象并组成一个辨识框架  $\Theta = \{F_1, F_2, \dots, F_N\}$ ,这些元素相互独立且两两互斥, $2^\Theta$  是  $\Theta$  的所有子集组成的幂集,满足  $\emptyset \in 2^\Theta, \Theta \in 2^\Theta$ .令映射  $m: 2^\Theta \rightarrow [0, 1]$  为一个定义在  $\Theta$  上的 BBA,满足  $m(\emptyset) = 0$ ,且  $\forall A \in 2^\Theta, \sum_{A \in 2^\Theta} m(A) = 1$ , $m(A)$  表示对命题  $A$  本身赋予的信度.若有  $m(A) > 0$ ,则称  $A$  为辨识框架  $\Theta$  上的一个焦点.在设备故障诊断中,辨识框架  $\Theta$  由设备的故障模式组成,而某信息源提供的诊断证据可以用 BBA 函数  $m$  来表示,例如“ $m(\{F_1\}) = 0.65, m(\Theta) = 0.35$ ”表示该信息源的故障特征取某个值时,对应发生故障  $F_1$  的信度为 0.65,“不知发生何种故障”的信度为 0.35.

如果  $m_1$  和  $m_2$  分别是两个定义在  $\Theta$  上的 BBA,定义  $m_3 = m_1 \oplus m_2$  为组合后的 BBA<sup>[1]</sup>,则有

$$m_3(C) = \frac{\sum_{A \cap B = C} m_1(A)m_2(B)}{1 - \sum_{A \cap B = \emptyset} m_1(A)m_2(B)}, \quad (1)$$

其中符号“ $\oplus$ ”表示融合算子.可令

$$\kappa = \sum_{A \cap B = \emptyset} m_1(A)m_2(B) \quad (2)$$

为规范化因子,用来表示两两证据之间的冲突程度大小,式(2)只有在  $\kappa < 1$  的情况才可以使用. Dempster 组合规则是在同一个辨识框架下综合处理多批证据的方法,是证据理论的核心.

1.2 K近邻算法及其改进

K近邻算法最初是由Cover和Hart在20世纪60年代提出的,经过了近50年的研究和探索,由于其简单、有效,已被广泛应用于机器学习和数据挖掘领域解决分类问题<sup>[9-10]</sup>.当它被应用于故障分类问题时,K近邻的原理如下例所示.

设待分类样本(测试样本)向量记为

$$Y_c = (y_{c,1}, y_{c,2}, \dots, y_{c,J}),$$

其中 $y_{c,j}(j = 1, 2, \dots, J)$ 表示可用于诊断的第j中故障特征参数 $f_j$ 的取值.若历史故障样本库中存在某个标记为故障 $F_i$ 的样本向量 $X_i = (x_{i,1}, x_{i,2}, \dots, x_{i,J}, F_i), i = 1, 2, \dots, N$ ,则可以计算 $Y_c$ 与 $X_i$ 之间的距离为

$$d(Y_c, X_i) = \sqrt{\sum_{j=1}^J (y_{c,j} - x_{i,j})^2}. \quad (3)$$

利用式(3)依次计算 $Y_c$ 与历史样本库中每个样本的距离,并统计出距离 $Y_c$ 最近的K个历史样本所属故障类别,属于哪个类别的样本数量最多,则判定 $Y_c$ 也指向该类别.K近邻分类的思路简单易行,但是所采用的“少数服从多数”的判定规则,在各故障类别历史样本的边界模糊时,易出现无法分类甚至错误分类的情况.例如,若 $K = 5$ ,最近邻样本中分别有2个属于 $F_1$ 和 $F_2$ ,1个属于 $F_3$ ,则不能确定 $Y_c$ 归入 $F_1$ 和 $F_2$ ,但是近邻样本中有3个属于 $F_1$ 、2个属于 $F_2$ 的情况(简称为“3-2”情况),此时则会出现误判.

为了解决此问题,Denoeux等在文献[8]中提出利用证据表示 $Y_c$ 与K个近邻样本之间的关系.例如,如果 $X_i$ 是其中的一个近邻样本,则所生成的证据为

$$\begin{cases} m(F_i) = \varphi_i(d), \\ m(\Theta) = 1 - \varphi_i(d). \end{cases} \quad (4)$$

其中: $d$ 为式(3)中 $Y_c$ 与 $X_i$ 之间的距离; $\varphi_i(d) = \alpha \exp(-\gamma_i \times d^2)$ , $\alpha$ 和 $\gamma_i$ 都为可调参数,可以通过历史样本进行优化.那么,K个近邻样本可以获得K个证据,利用式(1)将这K个证据进行组合,获取融合后的证据,融合结果中哪个故障类别的信度最高,则 $Y_c$ 属于哪类.由于采用BBA表示归类的信度,其要比“少数服从多数”的硬判决更为细致地刻画 $Y_c$ 与 $X_i$ 之间的关系,所以可以较好地处理“2-2-1情况”,但是难以处理“3-2”情况.因为用式(4)生成证据时,由于只对 $X_i$ 所属故障 $F_i$ 和全集 $\Theta$ 赋值,并未对其他故障类别赋值,没有充分考虑 $X_i$ 与其他故障类别近邻样本之间的相似程度(即各故障样本的边界模糊性问题),

即使采用证据融合,也不能很好地处理“3-2”这种情况<sup>[8,11]</sup>.

2 基于RFV的K近邻证据融合方法

由以上分析可见,文献[8]中的方法虽然引入证据融合思想来改进K近邻算法,但是生成证据的过程并没有充分度量近邻样本与其他故障类别样本之间的相似性关系,也没有对各故障类别样本边界之间的模糊性给予必要的建模与处理,不太适用于解决复杂的故障诊断问题.因此,本节给出一种新的K近邻证据融合方法,根据实际故障监测数据中存在的“随机噪声干扰”和“系统性误差”,利用RFV对各故障的历史样本进行建模,生成故障样板模式,然后用K近邻算法获取测试样本的近邻样本,并定义近邻样本的RFV型待检模式.计算待检模式和各个样板模式的匹配度从而获取近邻诊断证据,然后将它们融合并作出故障决策.这里首先给出RFV的概念,然后给出所提方法的实施步骤.

2.1 随机模糊变量(RFV)的定义

RFV是一种特殊的II型模糊变量<sup>[6]</sup>,如图1所示,对应 $\alpha$ 截集是II型置信区间,即

$$B = [[x_a^\alpha, x_b^\alpha], [x_c^\alpha, x_d^\alpha]], \alpha \in [0, 1]. \quad (5)$$

可见,通过组合内、外部两个隶属度函数可以得到相应的RFV,这种组合是通过 $\alpha$ 截集来截取内、外部隶属度函数两个I型置信区间的组合.使用RFV来对不确定性信息建模时,根据II型置信区间的定义,外部区间 $[x_a^\alpha, x_b^\alpha]$ 和 $[x_c^\alpha, x_d^\alpha]$ 的宽度表示监测数据的随机不确定性.内部区间 $[x_b^\alpha, x_c^\alpha]$ 表示系统性误差引起的不确定性,一般是依据传感器生产商提供的精度标准来确定.总体而言,测量不确定性中的随机性和系统性误差能够用RFV合理地表示,与文献[2]中的I型隶属度函数相比,更加精细地描述了不确定信息,能够捕捉到更多的有用信息.




图1 RFV和具有置信水平等于1 - alpha的置信区间

2.2 故障样板的(RFV)模型

对于给定的故障辨识框架 $\Theta = \{F_1, F_2, \dots, F_N\}$ ,在故障 $F_i$ 发生时,利用传感器连续采集某一个

故障特征  $f_j$  的  $Q$  个测量值  $\{x_1, x_2, \dots, x_Q\}$ ,  $400 \geq Q \geq 200$ , 构成历史样本集合; 用  $A_{ij}$  表示在故障  $F_i$  下的特征参数  $f_j$  的 RFV,  $A_{ij}$  由外部隶属度函数  $u_{out}(x)$  与内部隶属度函数  $u_{in}(x)$  组成. 这里首先建模  $u_{out}(x)$ , 由  $Q$  个测量值  $\{x_1, x_2, \dots, x_Q\}$  得到  $f_j$  的频率直方图, 然后对其进行插值拟合, 得出  $f_j$  正态分布的概率密度函数  $p_{f_j}(x)$ .

该正态分布的均值即为概率密度函数  $p_{f_j}(x)$  的峰值点  $x_p$ , 其隶属度为  $u_{out}(x) = 1$ , 对应的  $f_j$  变化范围  $[x_L, x_R] = [x_p - 3\sigma, x_p + 3\sigma]$ ,  $\sigma$  为标准差. 在区间  $[x_L, x_p]$  和  $[x_p, x_R]$  上分别均匀插入  $M$  个点  $x_{L_l}$  和  $x_{R_l}$ ,  $l = 1, 2, \dots, M$ , 它们将区间  $[x_L, x_p]$  和  $[x_p, x_R]$  分别等分为  $M + 1$  个子区间. 那么由这些点可以产生  $M + 2$  个嵌套性的子区间  $[x_p, x_p], [x_{L_M}, x_{R_M}], \dots, [x_{L_1}, x_{R_1}], \dots, [x_{L_1}, x_{R_1}], [x_L, x_R]$ , 利用  $p_{f_j}(x)$  在这些区间中的积分运算, 可以构造图 1 中外部区间形式的  $u_{out}(x)$ , 其中

$$u_{out}(x)|_{x=x_{L_l}, x_{R_l}} = 1 - \int_{x_{L_l}}^{x_{R_l}} p(x) dx, \quad l = 1, 2, \dots, M + 2. \quad (6)$$

此外, 当利用传感器对  $f_j$  测量时, 传感器的系统误差可以用内部隶属度函数  $u_{in}(x)$  描述, 其取决于传感器供应商提供的测量精度  $x(1 \pm \varepsilon\%)$ , 一般  $0.2 < \varepsilon < 2$ , 由此精度规格可以构造矩形的内部隶属度函数

$$u_{in}(x) = \begin{cases} 1, & x \in [x_p(1 - \varepsilon\%), x_p(1 + \varepsilon\%)] \\ 0, & x \notin [x_p(1 - \varepsilon\%), x_p(1 + \varepsilon\%)] \end{cases} \quad (7)$$

最终将  $u_{out}(x)$  和  $u_{in}(x)$  的  $\alpha$  水平截集结合, 即可得到特征  $f_j$  的随机模糊变量模型  $A_{i,j}$ . 具体地,  $u_{out}(x)$  和  $u_{in}(x)$  的  $\alpha$  水平截集分别为  $[x_{O_L}^\alpha, x_{O_R}^\alpha]$  和  $[x_{I_L}^\alpha, x_{I_R}^\alpha]$ , 由于  $u_{in}(x)$  为矩形, 显然有  $x_{I_L}^\alpha = x_p(1 - \varepsilon\%), x_{I_R}^\alpha = x_p(1 + \varepsilon\%)$ . 将  $[x_{O_L}^\alpha, x_{O_R}^\alpha]$  分为两个子区间  $[x_{O_L}^\alpha, x_p^\alpha]$  和  $[x_p^\alpha, x_{O_R}^\alpha]$ , 其中  $x_p$  为  $u_{out}(x)$  的峰值点. 那么,  $A_{ij}$  可由一组  $\alpha$  水平截集  $X_\alpha = \{x_a^\alpha, x_b^\alpha, x_c^\alpha, x_d^\alpha\}$  来定义, 这里  $x_c^\alpha = x_{I_R}^\alpha, x_b^\alpha = x_{I_L}^\alpha, x_d^\alpha = x_c^\alpha + (x_{O_R}^\alpha - x_p), x_a^\alpha = x_b^\alpha + (x_p - x_{O_L}^\alpha)$ , 并用如下形式的矩阵表示:

$$A_{i,j} = \begin{bmatrix} \alpha_1 & x_a^{\alpha_1} & x_b^{\alpha_1} & x_c^{\alpha_1} & x_d^{\alpha_1} \\ \alpha_2 & x_a^{\alpha_2} & x_b^{\alpha_2} & x_c^{\alpha_2} & x_d^{\alpha_2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \alpha_{M+2} & x_a^{\alpha_{M+2}} & x_b^{\alpha_{M+2}} & x_c^{\alpha_{M+2}} & x_d^{\alpha_{M+2}} \end{bmatrix}. \quad (8)$$

其中: 每行表示不同的  $\alpha$  水平截集及其  $\alpha$  值,  $\alpha_1 =$

$1 > \alpha_2 > \dots > \alpha_{M+2} = 0$ , 并有  $x_a^{\alpha_1} = x_b^{\alpha_1}, x_c^{\alpha_1} = x_d^{\alpha_1}$ . 显然,  $\alpha$  截集个数的增加会导致相应计算量的增加. 一般在实际应用中为了便于计算机的处理, 设定 RFV 的行数为 100, 这样一个 RFV 可以用一个  $100 \times 5$  的矩阵表示<sup>[6]</sup>.

### 2.3 K 近邻证据的生成

对于待分类的测试样本向量  $y_c = (y_{c,1}, y_{c,2}, \dots, y_{c,J})$  和历史样本库中每个样本向量  $X_i = (x_{i,1}, x_{i,2}, \dots, x_{i,J}; F_i)$ , 利用式 (3) 计算特征  $f_j$  的样本值  $y_{c,j}$  和  $X_i$  中  $f_j$  的样本值  $x_{i,j}$  之间的距离, 选取与  $y_{c,j}$  距离最近的  $K$  个样本, 记为邻近特征样本集  $\Phi = \{x_j^1, x_j^2, \dots, x_j^s, \dots, x_j^K\}$ ,  $s = 1, 2, \dots, K$ . 在构造这  $K$  个近邻样本的 RFV 模型时, 由于它们都是特征  $f_j$  在不同故障模式下的单次测量值, 无法分析单值所受到的随机性干扰的大小, 只能考虑系统性误差对该值的影响, 因为其中第  $K$  个近邻样本的 RFV 模型为矩形的隶属度函数:

$$u_j^s(x) = \begin{cases} 1, & x \in [x_j^s(1 - \varepsilon\%), x_j^s(1 + \varepsilon\%)] \\ 0, & x \notin [x_j^s(1 - \varepsilon\%), x_j^s(1 + \varepsilon\%)] \end{cases} \quad (9)$$

令  $x_b^s = x_j^s(1 - \varepsilon\%)$  和  $x_c^s = x_j^s(1 + \varepsilon\%)$  为  $u_j^s(x)$  取值为 1 的左右分界点, 那么近邻样本  $x_j^s$  的待检模式  $u_j^s(x)$  与每个故障特征的故障样板模式  $A_{i,j}$  的匹配程度  $\rho_j^s(F_i)$  可以分以下几种情况求取:

1) 当  $x_b^{\alpha_1} \leq x_b^s \leq x_c^{\alpha_1}$  或  $x_b^{\alpha_1} \leq x_c^s \leq x_c^{\alpha_1}$  时,  $u_j^s(x)$  与  $A_{i,j}$  的内部隶属度函数  $u_{in}(x)$  完全或者部分重合, 则

$$\rho_j^s(F_i) = 1. \quad (10)$$

2) 当  $x_b^s \geq x_a^{\alpha_{M+2}}$  且  $x_c^s < x_b^{\alpha_1}$  时,  $u_j^s(x)$  位于  $A_{i,j}$  的左侧, 则

$$\rho_j^s(F_i) = \begin{cases} \frac{\alpha_l - \alpha_{l+1}}{x_a^{\alpha_l} - x_a^{\alpha_{l+1}}} (x_c^s - x_a^{\alpha_{l+1}}) + \alpha_{l+1}, & x_a^{\alpha_{l+1}} \leq x_c^s \leq x_a^{\alpha_l}; \\ 0, & \text{else.} \end{cases} \quad l = 1, 2, \dots, N + 1. \quad (11)$$

通过对两个相邻截集之间的外部隶属度函数进行线性化, 利用线性化函数的斜率公式获取匹配度, 由于  $x_c^s$  比  $x_b^s$  更靠近  $A_{i,j}$  的  $u_{in}(x)$ , 这里计算关于  $x_c^s$  的斜率作为匹配度.

3) 当  $x_b^s > x_c^{\alpha_1}$  且  $x_c^s < x_d^{\alpha_{M+2}}$  时,  $u_j^s(x)$  位于  $A_{i,j}$  的右侧, 则

$$\rho_j^s(F_i) = \begin{cases} \frac{\alpha_l - \alpha_{l+1}}{x_d^{\alpha_l} - x_d^{\alpha_{l+1}}}(x_a^s - x_d^{\alpha_{l+1}}) + \alpha_{l+1}, & x_d^{\alpha_{l+1}} \leq x_a^s \leq x_d^{\alpha_l}; \\ 0, & \text{else.} \end{cases} \quad (12)$$

该式与式(11)是对偶关系,不再一一解释。

依照以上过程,即可计算 $u_j^s(x)$ 与每个故障的样板模式的匹配度 $\rho_j^s(F_i), i = 1, 2, \dots, N$ ,如图2所示。此时 $N = 4, u_j^s(x)$ 位于4个故障样板模式的左侧,利用式(11)可以求解匹配度。一般而言,所有 $\rho_j^s(F_i)$ 的取值之和不会为1,不能直接将其作为BBA使用,需要对它们进行归一化处理<sup>[1-2]</sup>:

$$\begin{cases} m_j^s(F_i) = \frac{\rho_j^s(F_i)}{\sum_{i=1}^N \rho_j^s(F_i) + \rho_j^s(\Theta)}, \\ m_j^s(\Theta) = \frac{\rho_j^s(\Theta)}{\sum_{i=1}^N \rho_j^s(F_i) + \rho_j^s(\Theta)}, \end{cases} \quad (13)$$

其中 $\rho_j^s(\Theta) = 1 - \max\{\rho_j^s(F_1), \rho_j^s(F_2), \dots, \rho_j^s(F_N)\}$ 。那么,对于特征 $f_j$ 的测试样本 $y_{c,j}$ ,它的近邻样本 $x_j^s$ 提供的证据为

$$m_j^s = m_j^s(F_1), \dots, m_j^s(F_N), m_j^s(\Theta). \quad (14)$$




图2 邻近样本待检模式RFV与各故障样板模式RFV的匹配

### 2.4 多特征近邻证据融合及故障决策

在获取测试样本 $y_c = (y_{c,1}, y_{c,2}, \dots, y_{c,J})$ 之后,依据2.3节的步骤,可以获得特征 $f_j$ 中 $y_{c,j}$ 的K条近邻证据,利用式(1)中的Dempster组合规则融合这K条证据,获取局部融合结果,记为 $m_j = \{m_j(F_1), \dots, m_j(F_N), m_j(\Theta)\}$ 。而后,再一次利用式(1)对共计J个特征的局部融合结果进行融合,即可得到全局融合结果 $m = \{m(F_1), \dots, m(F_N), m(\Theta)\}$ 。由于不同类型故障样本边界的模糊性,这里以最为宽松的判决条件进行故障决策,即鉴定的故障类型应具有最大的基本概率赋值。

根据以上判决条件获得的决策结果,可以构造出

如表1所示的混淆矩阵来衡量诊断算法在多次测试中的故障决策效果。

表1 故障决策结果的混淆矩阵

	$F_1$	$\dots$	$F_q$	$\dots$	$F_N$
$F_1$	$k_{1,1}$	$\dots$	$k_{1,q}$	$\dots$	$k_{1,N}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$
$F_p$	$k_{p,1}$	$\dots$	$k_{p,q}$	$\dots$	$k_{p,N}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\ddots$	$\vdots$
$F_N$	$k_{N,1}$	$\dots$	$k_{N,q}$	$\dots$	$k_{N,N}$

表1中测试样本的总量用 $T = \sum_{p=1}^N \sum_{q=1}^N k_{p,q}$ 表示,

$k_{p,q}$ 表示真实故障是 $F_p$ 而诊断结果为 $F_q$ 的测试样本数量。那么,该矩阵对角线元素之和与样本总量的比即为总确诊率

$$R = \frac{k_{1,1} + k_{2,2} + \dots + k_{N,N}}{T}. \quad (15)$$

显然,R越大,说明诊断效果越好,所以在随后的诊断实验中,将用该指标衡量各种诊断算法性能的优劣。

## 3 电机柔性转子故障诊断实例与对比分析

### 3.1 实验设置

下面通过电机柔性转子实验来验证本文方法的有效性。选择ZHS-2型多功能柔性转子试验台作为实验设备,在转子支撑座的水平和垂直方向安装振动位移传感器和加速度传感器,并使用这些传感器采集转子振动信号,经HG-8902采集箱将信号传输至计算机,然后利用Labview环境下的HG-8902数据分析软件得到转子振动加速度频谱作为故障特征信号<sup>[1-2]</sup>。

在实验台上设置4种模式:正常运行 $F_1$ ,转子不平衡 $F_2$ ,转子不对中 $F_3$ ,基座松动 $F_4$ 。通过对大量实验数据的分析可知,引发异常振动的故障源都会产生一定频率成分的振动幅值增加或减少。因此,这里选取1X~3X倍频作为故障特征变量。设定转子转速为1500r/m,则基频为1X=25Hz,n倍频为nX=25nHz, n=1,2,⋯。故障特征可以选择频域的1X、2X和3X的振动幅值,记为 $f_1, f_2$ 和 $f_3$ 。根据振动传感器出厂标定,其系统误差为 $\Delta = \pm \varepsilon \% = \pm 1 \%$ 。

由上述实验设置可确定本实验的故障辨识框架 $\Theta = \{F_1, F_2, F_3, F_4\}$ 。在每种故障模式下,获取特征 $f_1 \sim f_3$ 各300次测量结果。在每种故障模式下,对于这3种故障特征,样本总数有300×4个,则随机选取其中的200×4个作为历史(训练)样本库,剩下的100×4构成测试样本集。利用每种特征的历史样本,可以构造4种故障的样板模式RFV分别如图3~图5所示。




图3 故障特征1X下,4种故障的样板模式RFV




图4 故障特征2X下,4种故障的样板模式RFV




图5 故障特征3X下,4种故障的样板模式RFV

3.2 所提方法与其他相关诊断方法的对比与分析

在获取故障样板模式的RFV之后,对于  $100 \times 4$  个测试样本,利用本文所提方法给出的故障决策结果如表2所示,其中近邻样本数量取值  $K = 5$ 。

表2 本文方法的故障决策结果

	$F_1$	$F_2$	$F_3$	$F_4$	$\Theta$
$F_1$	86	14	0	0	0
$F_2$	5	93	1	1	0
$F_3$	0	4	90	6	0
$F_4$	0	0	4	96	0

进一步地,将该结果与以下4种方法进行对比。

方法1:文献[2]中的诊断证据融合方法,用高斯隶属度函数对故障样板模式建模,而该实验中,为了便于对比,利用单个测试样本点构造待检模式,不再使用多次测量结果中提取的隶属度函数;方法2:文献[7]中采用RFV模型构造故障样板模式和待检模式,利用 $\alpha$ 截集匹配获取证据,这里为了便于对比,待检模式来自单个样本提供的矩形RFV;方法3:最基本的KNN方法,故障类型的判断采用“少数服从多数”的原则;方法4:Denoeux在文献[7]中提出的KNN和证据融合相结合的方法,计算测试样本向量与最近的5个近邻样本向量之间的距离,并用于式(4)生成证据,

其中可调参数利用历史样本库中的样本对其进行了优化,最后用式(1)融合这些证据。这4种方法给出的故障决策结果分别如表3和表4所示。

表3 方法1/方法2的故障决策结果

	$F_1$	$F_2$	$F_3$	$F_4$	$\Theta$
$F_1$	84/98	16/2	0/0	0/0	0/0
$F_2$	9/5	87/90	2/1	2/0	0/1
$F_3$	0/0	5/7	88/78	5/6	2/9
$F_4$	0/8	2/1	6/3	86/84	1/4

表4 方法3/方法4的故障决策结果

	$F_1$	$F_2$	$F_3$	$F_4$	$\Theta$
$F_1$	60/60	40/40	0/0	0/0	0/0
$F_2$	0/0	84/90	7/6	6/4	3/0
$F_3$	0/0	0/0	89/89	11/11	0/0
$F_4$	0/0	0/0	2/2	98/98	0/0

在这次实验当中,每种方法的故障确诊率如表5所示。

表5 5种方法的确诊率比较 %

	本文方法	方法1	方法2	方法3	方法4
确诊率	91.25	86.25	87.5	82.75	84.25

从以上对比分析可以看出:本文所提方法具有最高的确诊率,方法2次之,而证据融合与KNN相结合的方法(方法4)优于单纯的KNN方法(方法3)。其中:方法2考虑了故障数据的系统性误差和随机噪声干扰,利用RFV对故障进行建模,相比方法1所使用的模糊变量方法更为精细;方法3中出现了“2-2-1”情况,不能用“少数服从多数”的准则作出决策,而方法4将KNN与证据理论结合,使用更多的证据来表示待测样本的不确定性,同时解决了“2-2-1”情况;方法1和方法2中也出现了故障决策结果不确定的情况,表明融合结果对全集 $\Theta$ 的基本信度赋值大于其他故障模式的赋值;本文综合RFV模型、KNN与证据理论的优点,与方法2相比,本文2.3节获取证据的匹配方法优于方法2中利用 $\alpha$ 截集匹配获取证据的方法,与方法4相比,通过本文方法生成的证据不仅对近邻样本所属故障和全集赋值,而且考虑了与其他故障类别样本之间的边界模糊性问题,对其他故障类别赋予了一定的信度,最终的融合结果在信度聚焦上明显优于方法4。

这里,进一步利用测试样本中的实例说明所提方法的性能优于其他几种方法。

实例1 “2-2-1”情况. 测试样本取值

$$y_c = (y_{c,1}, y_{c,2}, y_{c,3}) = (0.2314, 0.2303, 0.1724),$$

它对应的真实故障为 $F_2$ 。对于此测试样本,它的5个

近邻历史样本向量中分别有两个指向  $F_3$  和  $F_4$ 、一个指向  $F_2$ 。那么,按照“少数服从多数”的原则,KNN无法给出确切诊断结果,亦即“2-2-1”情况。

方法1: 3种特征提供的证据分别为

$$(0, 0.2555, \mathbf{0.5069}, 0.0011, 0.2365),$$

$$(0.0014, 0.2941, 0.0036, 0.0023, \mathbf{0.6986}),$$

$$(0.0402, 0.2664, 0.0893, \mathbf{0.5529}, 0.0513).$$

它们的融合结果为

$$(0.0209, \mathbf{0.4601}, 0.2035, 0.289, 0.0266),$$

该结果指向  $F_2$ 。

方法2: 3种特征提供的证据分别为

$$(0.0097, 0.2197, 0.3483, 0.0115, \mathbf{0.4109}),$$

$$(0.0225, 0.1633, 0.0122, 0.0074, \mathbf{0.7946}),$$

$$(0.0903, 0.2647, 0.0266, \mathbf{0.3706}, 0.2478).$$

它们的融合结果为

$$(0.0629, \mathbf{0.4079}, 0.1555, 0.2294, 0.1443),$$

该结果也指向  $F_2$ 。

方法4: 通过式(4)生成这5个近邻样本的证据向量  $(m(F_1), m(F_2), m(F_3), m(F_4), m(\Theta))$  为

$$(0, 0, \mathbf{0.7166}, 0, 0.2834),$$

$$(0, 0, \mathbf{0.71}, 0, 0.29),$$

$$(0, 0, 0, \mathbf{0.651}, 0.349),$$

$$(0, 0, 0, \mathbf{0.6475}, 0.3524),$$

$$(0, \mathbf{0.9499}, 0, 0, 0.0501).$$

可见这5个证据各自的决策结果仍然是“2-2-1”的情况,但是将它们融合后获得的证据为

$$(0, 0.4956, 0.2919, 0.1861, 0.0261),$$

信度赋值聚焦于  $F_2$  则可以判断此时  $F_2$  发生。但是,这3种方法对真实发生故障  $F_2$  的信度赋值都偏低,使得决策的可靠性不高。

本文方法: 3个特征提供的局部融合证据分别为

$$(0, 0.3076, \mathbf{0.6924}, 0, 0),$$

$$(0.1266, \mathbf{0.7099}, 0.053, 0.0309, 0.0796),$$

$$(0.0001, 0.0435, 0.0006, \mathbf{0.9558}, 0),$$

再将它们融合,得到全局证据

$$(0, \mathbf{0.9952}, 0.0048, 0, 0).$$

由于采用了RFV建模及相应的匹配方法,加之使用“局部和全局”两层融合的聚焦作用,使得  $F_2$  的信度达到0.9952,显示了所提方法给出的决策结果要比其

他几种方法更为可靠和可信。

**实例2** “3-2”情况. 测试样本取值

$$y_c = (y_{c,1}, y_{c,2}, y_{c,3}) = (0.268, 0.3631, 0.1819),$$

它对应的真实故障为  $F_4$ 。对于此测试样本,它的5个近邻历史样本向量中分别有3个指向  $F_3$ 、2个指向  $F_4$ 。KNN误判为  $F_3$ ,亦即“3-2”情况。

方法1: 3种特征提供的证据分别为

$$(0, 0.0575, 0.1878, 0.0261, \mathbf{0.7287}),$$

$$(0, 0.0001, 0.499, \mathbf{0.5009}, 0),$$

$$(0.0226, 0.1984, 0.1268, 0.0261, \mathbf{0.7287}).$$

融合结果为

$$(0, 0, 0.3556, \mathbf{0.6444}, 0),$$

信度赋值聚焦于  $F_4$ , 诊断正确。

方法2: 3种特征提供的证据分别为

$$(0.0030, 0.0720, 0.1411, 0.0434, \mathbf{0.7405}),$$

$$(0.0002, 0.0016, \mathbf{0.3538}, 0.3334, 0.3110),$$

$$(0.0691, 0.2125, 0.0386, \mathbf{0.3578}, 0.3220).$$

融合结果为

$$(0.0293, 0.1103, 0.2456, \mathbf{0.4820}, 0),$$

信度赋值也聚焦于  $F_4$ , 诊断正确。

方法3: 5个近邻样本的证据向量为

$$(0, 0, \mathbf{0.8431}, 0, 0.1569),$$

$$(0, 0, \mathbf{0.8401}, 0, 0.1599),$$

$$(0, 0, \mathbf{0.8340}, 0, 0.166),$$

$$(0, 0, 0, \mathbf{0.8016}, 0.1984),$$

$$(0, 0, 0, \mathbf{0.7925}, 0.2075).$$

可见这5个证据各自的决策结果仍然是“3-2”的情况,并且  $F_3$  整体上获取的信度赋值高于  $F_4$ , 所以导致融合结果  $(0, 0, \mathbf{0.9078}, 0.0884, 0.0038)$  聚焦于  $F_3$ , 致使诊断结果错误。

本文方法: 3个特征提供的局部融合证据分别为

$$(0, 0.0077, 0.0507, \mathbf{0.7195}, 0.222),$$

$$(0, 0, \mathbf{0.5019}, 0.4981, 0),$$

$$(0.0012, 0.0559, 0.0237, \mathbf{0.9175}, 0.0017),$$

再将它们融合,得到全局证据为

$$(0, 0, 0.008, \mathbf{0.992}, 0),$$

其中  $F_4$  的信度高达0.992, 远远高于方法1和方法2给出的信度赋值,其原因在于采用了新型的RFV模型及近邻证据融合策略,从而捕捉到故障特征中更为丰

富的诊断信息.

最后,为了验证方法的稳定性,进一步对各种故障进行实验,产生20组 $100 \times 4$ 的数据作为测试样本,对以上4种方法进行测试,所得到的平均确诊率与表6给出的单次确诊率基本持平,这进一步说明了所提方法的有效性和稳定性.

## 4 结 论

本文针对已有的证据融合故障诊断方法所存在的两个主要问题展开,一是故障数据建模准确性问题,亦即如何有效区分并建模故障特征信息表现出的“随机噪声干扰”和“系统性误差”;二是诊断的实时性问题,亦即如何协调“长时间的多次测量数据用于诊断,保证诊断的可靠性”与“单次测量数据用于诊断,保证诊断的快速性”之间的矛盾.这些都是在复杂的工业环境中,建立智能故障报警系统时必须考虑的重点问题.

本文针对这些问题,提出了一种近邻诊断证据融合方法.由于RFV模型能够区分并精确描述“随机噪声干扰”和“系统性误差”这两种截然不同的变量不确定性,对于每种故障特征(征兆),利用它的历史样本数据构建RFV形式的故障样板模式,基于KNN算法获得离测试样本最近的 $K$ 个历史样本,并定义这 $K$ 个样本的RFV型待检模式.匹配待检RFV与样板RFV以获取 $K$ 个诊断证据,然后融合不同故障特征的 $K$ 个诊断证据,在融合结果的基础上对测试样本作出故障决策. $K$ 近邻思想的应用有效地将单点数据扩展为多点信息用于诊断,在保证诊断时效性的同时,充分挖掘了能够用于当前诊断的历史信息,兼顾了诊断的可靠性与时效性.最后,通过在电机柔性转子上的故障诊断实验,系统分析和说明了相比于其他3种方法,新方法的优势所在.

## 参考文献(References)

[1] 文成林, 徐晓滨. 多源不确定信息融合理论及应用故障诊断与可靠性评估[M]. 北京: 科学出版社, 2012: 248-249.  
(Wen C L, Xu X B. Multi-source uncertain information fusion theory and its application in fault diagnosis and reliability evaluation[M]. Beijing: Science Press, 2012:

248-249.)

- [2] 徐晓滨, 文成林, 王迎昌. 基于模糊故障特征信息的随机集度量信息融合诊断方法[J]. 电子与信息学报, 2009, 31(7): 1635-1640.  
(Xu X B, Wen C L, Wang Y C. Information fusion algorithm of fault diagnosis based on random set metrics of fuzzy fault features[J]. J of Electronics and Information Technology, 2009, 31(7): 1635-1640.)
- [3] Xu X B, Zhang Z, Xu D L, et al. Interval-valued evidence updating with reliability and sensitivity analysis for fault diagnosis[J]. Int J of Computational Intelligence Systems, 2016, 9(3): 396-415.
- [4] Marhic B, Delahoche L, Solau C, et al. An evidential approach for detection of abnormal behaviour in the presence of unreliable sensors[J]. Information Fusion, 2012, 13(2): 146-160.
- [5] Yuan K, Xiao F, Fei L, et al. Modeling sensor reliability in fault diagnosis based on evidence theory[J]. Sensors, 2016, 16(1): 113-123.
- [6] Ferrero A, Salicone S. Modeling and processing measurement uncertainty within the theory of evidence: Mathematics of random-fuzzy variables[J]. IEEE Trans on Instrumentation and Measurement, 2007, 56(3): 704-716.
- [7] Xu X B, Zhou Z, Wen C L. Data fusion algorithm of fault diagnosis considering sensor measurement uncertainty[J]. Int J on Smart Sensing & Intelligent Systems, 2013, 6(1): 171-190.
- [8] Denoeux T. A  $k$ -nearest neighbor classification rule based on Dempster-Shafer theory[J]. IEEE Trans on Systems, Man, and Cybernetics, 1995, 25(5): 804-813.
- [9] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE Trans on Information Theory, 1967, 13(1): 21-27.
- [10] Hastie T, Tibshirani R. Discriminant adaptive nearest neighbor classification[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1996, 18(6): 607-616.
- [11] Pal N R, Ghosh S. Some classification algorithms integrating Dempster-Shafer theory of evidence with the rank nearest neighbor rules[J]. IEEE Trans on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2001, 31(1): 59-66.

(责任编辑: 齐 霁)