

基于数据挖掘与信息融合的制冷设备故障诊断*

周旖璠¹, 武凯¹, 孙宇¹, 杨晓燕², 楼晓华²

(1. 南京理工大学机械工程学院 南京, 210094) (2. 南通四方科技集团股份有限公司 南通, 226300)

摘要 针对传统制冷设备监控系统对单一故障检测较为准确但难以对并发故障做出判断的局限性, 提出一种基于指定元分析和支持向量机两种数据挖掘方式的信息融合方法对制冷设备并发故障进行诊断。首先, 基于传统指定元分析不适用于非完全正交模式, 对指定元分析算法进行改良, 提出了一种非完全正交指定元分析方法; 其次, 通过实验证明非完全正交指定元分析与支持向量机模型均具有识别并发故障的能力, 且各自在不同并发故障识别有一定优势; 最后, 采用加权证据理论对两种模型的诊断结果进行信息融合, 融合后诊断效果得到进一步提升。结果表明: 命中率提升至 99.10%, 虚警率降低至 0.21%。

关键词 制冷设备; 并发故障; 信息融合; 指定元分析; 支持向量机

中图分类号 TP277; TH184

引言

制冷设备几种故障同时发生时, 各单发故障间会相互影响、相互诱导、相互耦合, 增加故障诊断系统的误报率和漏报率。因此, 开展制冷设备并发故障的诊断具有重要的应用价值。Macalister 等^[1]基于图论建立了制冷设备的故障诊断模型, 但这种模型面对较为复杂的系统时可能给出无效诊断结果。Salvatore 等^[2]将专家经验的知识库与推理机制相结合对制冷设备故障进行诊断, 但这类方法推理过程中存在匹配冲突等问题。Flore 等^[3]基于主元分析方法在制冷设备故障检测中建立主元模型, 通过对比测量数据与正常数据的统计量判断制冷设备是否发生故障, 然而这种诊断方法只能执行单一故障诊断。Kumar^[4]基于指定元分析 (designated cell analysis, 简称 DCA) 方法对制冷系统故障进行了诊断, 但由于 DCA 方法仅在各特征向量相互正交的情况适用, 因此当用于并发故障诊断时, 诊断结果不够准确。韩华等^[5]把支持向量机 (support vector machines, 简称 SVM) 模型用于制冷设备故障诊断研究并得到了较为准确的诊断结果。

为准确检测出制冷设备的并发故障, 提出一种基于数据挖掘与信息融合的并发故障诊断方法。首先, 采集设备正常工况数据和各类单发故障与并发故障下的数据, 并分别建立指定元分析模型和支持向量机模型, 为了使指定元分析方法适用于非正交

模式, 对原来的算法进行改良, 提出非完全正交指定元分析方法 (non-fully orthogonal designated cell analysis, 简称 NFODCA); 其次, 采用上述两种数据挖掘方法诊断制冷设备故障并进行实验验证; 最后, 采用加权证据理论对两种方法的诊断结果进行信息融合以提高诊断结果的可信度。

1 故障数据获取

制冷设备可能产生的故障类型较多, 根据经验知识对制冷系统的工作原理进行深入分析后, 选取了 6 类较为典型的单发故障, 通过故障随机组合形成并发故障进行研究, 所选取的 6 类典型故障如下: ①压缩机的吸排气阀片受损, 当这类故障发生时, 压缩机的实际输气量下降, 制冷效果降低; ②制冷剂不足, 制冷剂短缺的原因通常有两个, 一种是制冷剂在出厂前充注不足, 另一种是由于阀门或焊点松动导致的制冷剂泄漏; ③循环水泵不转, 这种故障会造成压缩机吸排气温度迅速上升, 同时冷凝器的冷却效果也会急剧下降; ④冷却水的流量太小, 冷却塔的水垢太大或冷却塔内部布置不当可能导致冷却水流量太小; ⑤膨胀阀开度过小, 当这种故障发生时会造成制冷设备循环的制冷剂不足; ⑥过滤器堵塞, 过滤网用于过滤灰尘和金属碎屑等, 使用时间过长易被堵住。

实验对象为一台需配冷量为 55 kW 的制冷机

* 国家国际科技合作专项资助项目 (2017DFR70090); 江苏省高端装备研制赶超资助项目 (JSTXZB201706)

收稿日期: 2019-03-04; 修回日期: 2019-05-27

组,在原有设备基础上引入制冷设备故障模拟及参数测试组件,通过实验采集故障数据。各故障的实现方法如下:①压缩机吸排气阀片损坏,在压缩机吸、排气管路之间设旁通通路,并安装针阀或计量阀作为旁通量调节装置;②制冷剂不足,先将系统抽真空,然后通过逐步加注实现不同程度制冷剂不足的故障模拟;③循环水泵不转,断开水泵控制电路即可模拟循环水泵不转的故障;④冷却水流量过小,降低旁通流量或减少冷却水闸阀开度均可改变冷却水量;⑤膨胀阀开度过小,将手动调节阀置于电磁阀与蒸发器之间以模拟膨胀阀开度过小;⑥过滤器堵塞,将一定比例的滤网面积用均布孔洞的厚纸挡住可以模拟过滤器堵塞引起的故障。故障模拟及参数测试组件安装位置如图 1 所示。

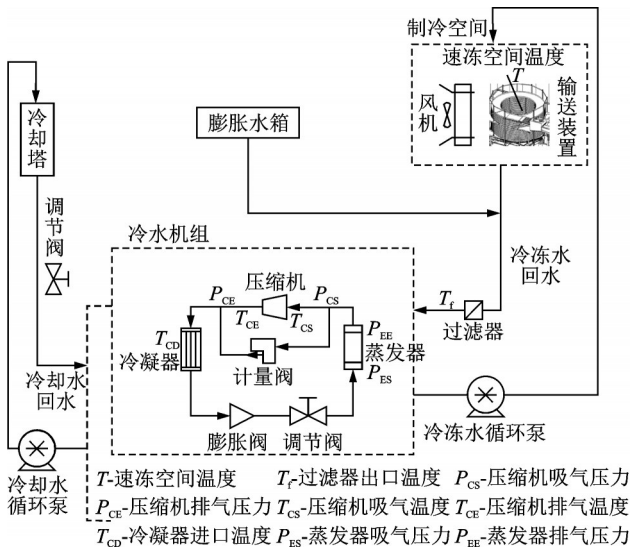


图 1 故障模拟及参数测试组件安装位置

Fig.1 Fault simulation and parameter test component installation location

2 非完全正交指定元分析

2.1 非完全正交指定元分析模型建立

由于NFODCA模型在建立时无需并发故障数据作为训练集,仅在验证模型阶段需要并发故障的数据。因此,将2/3的单发故障数据和2/3正常工况数据作为训练集用于模型建立,将并发故障数据、剩下的1/3类单发故障数据和1/3正常工况数据作为测试集用于模型验证。

制冷设备的故障现象、故障原因之间的关系可以用故障征兆集描述,征兆用测量值与标称值的偏差度表示。根据实际运行经验和论证分析,在制冷设备系统运行过程中对压缩机吸气压力上升、冷凝器进口温度上升等12种征兆进行监测,则每种征兆

$u_r (r = 1, 2, \dots, 12)$ 可表示为

$$u_r = \begin{cases} 1 & \text{第 } r \text{ 种征兆出现} \\ 0 & \text{第 } r \text{ 种征兆不出现} \end{cases} \quad (r = 1, 2, \dots, 12) \quad (1)$$

将故障种类的数目记为 s , 则 s 种故障 D_s 可定义为论域 U 中的 6 种指定模式

$$D_s = [d_{s1}, d_{s1}, \dots, d_{sr}] \quad (r = 1, 2, \dots, 12) \quad (2)$$

其中

$$d_{sr} = \begin{cases} 1 & \text{(模式 } s \text{ 呈现征兆 } r) \\ 0 & \text{(模式 } s \text{ 不呈现征兆 } r) \end{cases} \quad (3)$$

选取 6 种单发故障:压缩机吸排气阀片损坏 d_1 、制冷剂不足 d_2 、循环水泵不转 d_3 、冷却水流量过小 d_4 、膨胀阀开度过小 d_5 、过滤器堵塞 d_6 ; 2 种单发故障组合成的 7 类并发故障: $d_7 = d_1 + d_3$, $d_8 = d_1 + d_6$, $d_9 = d_2 + d_5$, $d_{10} = d_3 + d_4$, $d_{11} = d_3 + d_6$, $d_{12} = d_4 + d_5$, $d_{13} = d_5 + d_6$; 3 种单发故障组合而成的 3 类并发故障 $d_{14} = d_1 + d_2 + d_4$, $d_{15} = d_3 + d_4 + d_6$, $d_{16} = d_4 + d_5 + d_6$ 共计 16 种故障和正常工况进行实验数据采集。以上故障类型根据经验知识结合实际工况选出,其他类型的单发故障及其他组合形成的并发故障也可采用文中所述的研究方法。

把故障征兆定义为压缩机排气压力上升 u_1 、下降 u_2 , 压缩机吸气压力上升 u_3 、下降 u_4 , 压缩机排气温度上升 u_5 、下降 u_6 , 压缩机吸气温度上升 u_7 、下降 u_8 , 冷凝器出口温度上升 u_9 、下降 u_{10} , 过滤器温度上升 u_{11} 、下降 u_{12} , 分析实验结果可得故障与征兆间关系如表 1 所示。

表 1 制冷装置故障与征兆间关系

Tab.1 The relationship between faults and symptoms of this quick freezing device

u	u_1	u_2	u_3	u_4	u_5	u_6	u_7	u_8	u_9	u_{10}	u_{11}	u_{12}
d_1	0	1	0	1	0	1	1	0	0	0	0	0
d_2	0	1	0	1	1	0	1	0	0	1	0	0
d_3	0	1	1	0	0	0	0	1	0	0	1	0
d_4	1	0	0	0	1	0	1	0	0	0	0	0
d_5	1	0	1	0	1	0	0	0	0	1	0	0
d_6	0	0	0	0	0	1	0	1	0	0	0	1

由表 1 可知,按照式(2)定义的故障模式并非全部正交,例如:发生压缩机吸气阀片损坏时会导致压缩机吸气压力下降,而发生循环水泵不转的故障时会间接导致压缩机吸气压力上升;当这两种故障同时发生时,二者的故障特征会相互影响甚至抵消,而传统指定元分析算法仅在正交模式下适用;这两种不相互正交的故障同时发生时,将造成故障漏报。

所以对传统指定元分析方法进行改良,使之适用于非完全正交模式。

当样本数据 Y 处于完全正交模式时, Y 具有指定元的分解式^[6]

$$Y = \sum_{i=1}^h d_i w_i \quad (4)$$

其中: Y 由正常子空间和故障子空间组成; d_i 为正交指定模式; w_i 为相应指定元。

当 Y 处于非完全正交模式时可以表示为

$$Y = \sum_{i=1}^h d_i w_i + E \quad (5)$$

其中: E 为残差空间。

以 EE^T 最小为原则将指定模式集划分为 m 个组内正交的子集, 样本数据 Y 就可以表示为组内正交子集与残差阵的和

$$Y = D_1 W_1 + D_2 W_2 + \dots + D_m W_m + E \quad (6)$$

各子集指定元显著性可用式(7)计算得出

$$D_{mi} \% = \left\| D_{mi}^T Y_m \right\|^2 / \left\| Y_m \right\|^2 \quad (7)$$

在指定模式 d_i 所表示方向上用式(8)将样本数据 Y 做投影, 即可得到相应的指定元 w_i :

$[w_{i1}, w_{i2}, \dots, w_{in}] =$

$$[d_{i1}, d_{i2}, \dots, d_{im}] \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \vdots & \vdots & & \vdots \\ y_{m1} & y_{m2} & \dots & y_{mn} \end{bmatrix} \quad (8)$$

其中: n 为样本数量。

例如: $[y_{11}, y_{21}, \dots, y_{m1}]^T$ 表示第1组样本数据第 m 个指定模式下的特征向量。计算得到的 w_m 表示第 i 个指定元下第 n 个样本所对应的映射值, 组成如下的特征向量

$$w_{di} = (w_{i1}, w_{i2}, \dots, w_{in}) \quad (9)$$

最后, 根据正常工况下的数据计算出每个指定元对应特征值的控制上下限并得到 Shewhart 图, 若图中特征值超过了控制限, 则认为制冷设备发生了相应故障。

2.2 实例验证

从测试集中随机选取实验数据, 用 NFODCA 模型进行故障诊断, 并将诊断结果与故障模拟实验所采集数据的故障记录对比, 验证模型的可靠性。

根据表1中的制冷装置故障与征兆间关系和 EE^T 最小原则, 将非完全正交的模式集 $D = \{d_1, d_2, \dots, d_6\}$ 表示成3组组内正交的模式子集, 根据式(6), 样本数据 Y 可以表示为

$$Y = D_1 W_1 + D_2 W_2 + D_3 W_3 + E \quad (10)$$

即当非完全正交模式集 D 划分为3个组内相互正交的模式子集时, Y 可由各投影空间完全表示。

随机选取一组实验数据, 分别关于 D_1, D_2, D_3 做指定元分析, 根据式(7)计算出该组数据对应的各个指定模式的显著性如表2所示。

表2 对应各指定模式的显著性

Tab.2 Corresponding to the saliency of each designated mode

显著性	d_1	d_2	d_3	d_4	d_5	d_6
$d_i/\%$	0.36	0.02	0.03	0.45	0.10	0.36

从表2可以看出, 该组数据对应的6种指定模式中, d_1, d_4, d_6 对系统的影响较大, 据此可以初步判断系统中可能发生了压缩机吸排气阀片损坏、冷却水流量过小、过滤器堵塞三种故障。为了进一步验证该方法的合理性, 根据正常工况数据在置信度为95%的条件下计算出各个指定模式 d_i 的控制下限 L_i 及上限 U_i 为

$$d_1: L_1 = -5.918; U_1 = 5.907$$

$$d_2: L_2 = -6.687; U_2 = 6.745$$

$$d_3: L_3 = -3.902; U_3 = 3.821$$

$$d_4: L_4 = -4.536; U_4 = 4.372$$

$$d_5: L_5 = -5.554; U_5 = 5.563$$

$$d_6: L_6 = -3.924; U_6 = 3.798$$

将 Y 在所有指定元上进行投影, 根据上文计算出的控制限在图2中给出各指定元的 Shewhart 图, 图中 U, L 分别为控制上、下限, 横坐标为样本编号, 纵坐标表示由式(8), (9)得出的第 i 个指定元下第 n 个样本所对应映射值组成的特征向量的特征值, 该量无单位。

从图2可以看出, 第1, 4, 6个指定元的 Shewhart 图在第270个采样点以后超出了控制限, 而第2, 3, 5个指定元的特征值仍稳定在控制限以内, 证明制冷设备从第270个点开始出现了 d_1, d_4, d_6 3种类型的故障。

将故障诊断结果与故障模拟实验采集数据的故障记录对比, 结果表明, 诊断结果与采集数据时的记录一致。同理可得到其他测试集数据经 NFODCA 模型分析后的诊断结果, 并与故障模拟实验采集数据的故障记录对比, 最终得出 NFODCA 模型的故障诊断准确率为96.94%, 虚警率为0.48%, 证明文中提出的非完全正交指定元分析方法能准确判断制冷设备的并发故障, 是一种有效的多故障诊断方法。

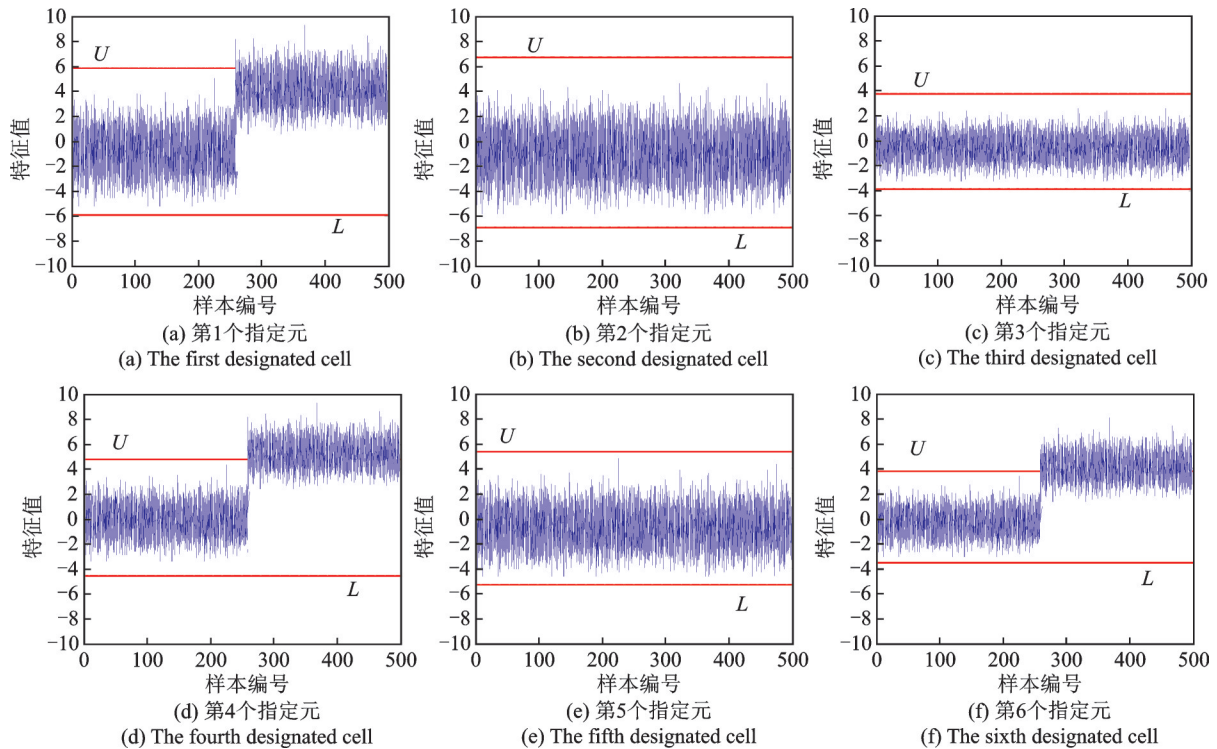


图2 各指定元的 Shewhart 图

Fig.2 Shewhart diagram of each designated cell

3 支持向量机

3.1 SVM 模型建立

考虑到 SVM 模型的诊断效果需要与前面的 NFODCA 模型对比,仍采用前面的 2/3 单发故障数据和 2/3 正常工况数据作为训练集,并发故障数据和剩下的 1/3 单发故障、1/3 正常工况数据作为测试集。通过对训练集进行训练,优化 SVM 参数,建立模型,并用测试集数据验证 SVM 模型的可靠性。

SVM 的主要参数包含惩罚参数 c 以及核函数参数 g ,通常对于这两个参数的选择是经过大量的实验分析得出的^[7],耗时耗力。为了快速得到最佳的参数 c 和 g ,使 SVM 的分类效果更好,采用网格寻优和 K-折交叉验证方法。网格寻优即先在一定范围上粗略选择找出 c 和 g ,然后在 c, g 周围进行参数的精细选择^[8]。K-折交叉验证方法的主要参数为折叠次数 K ,文中取 $K=5$,即 5 折交叉验证方法。首先把制冷设备的数据样本分类成 5 组子集,将前 4 组样本作为训练集,最后 1 组样本用于测试,然后循环 4 次,每次都得出一个均方误差 (mean square error, 简称 MSE)。将数据进行 5 次训练,且每次训练后将得到的数据进行整理分析,然后将 5 次的 MSE 取平均值。最后以 MSE 最小原则选取 c 值和 g 值作为 SVM 建模的最优参数^[9]。

根据前面得出的最优参数,按照分而治之的原则,总故障样本集 Y 首先按 d_1 故障分为正样本 (含有 d_1 故障样本) F_{d_1} 和负样本 (不含 d_1 的故障样本) F_{Nd_1} ,然后对这个二值分类问题建立 SVM- d_1 分类器^[10];同理,再将 Y 分别按故障 d_2, d_3, d_4, d_5, d_6 建立二值分类器。如果 Y 由多个分类器诊断为包含故障,则根据表决原则,判定故障样本 Y 包含多个故障^[11]。

假设样本数据 Y 为含有 d_2, d_3 故障的数据,首先用 SVM- d_1 分类器对其进行诊断, Y 通过诊断表现为不含 d_1 故障,则其决策函数 R_1 可以定义为 0;然后将 Y 用 SVM- d_2 分类器诊断, Y 通过诊断表现含有 d_2 故障,则其决策函数 R_2 可以定义为 1;同理得到决策函数 R_3, R_4, R_5, R_6 的值。这样诊断下来综合的评定决策函数 R 表现为 0/1/1/0/0/0,由此可以得到此时的故障 Y 同时含有 d_2, d_3 故障,同理可以得到其他各类故障所对应的决策函数。

3.2 SVM 模型验证

首先找出 SVM 的主要参数即惩罚参数 c 和核函数参数 g , SVM 模型在数据处理过程中自动选择了参数 $c=10, g=0.1$,这是随机得到的结果,具有主观性。因此通过网格寻优的方法优化参数,图 3 为参数 c 和 g 的粗略优化和精细优化过程,横坐标表示

$\log_2 c$ 的范围,纵坐标表示 $\log_2 g$ 的范围,均无量纲。

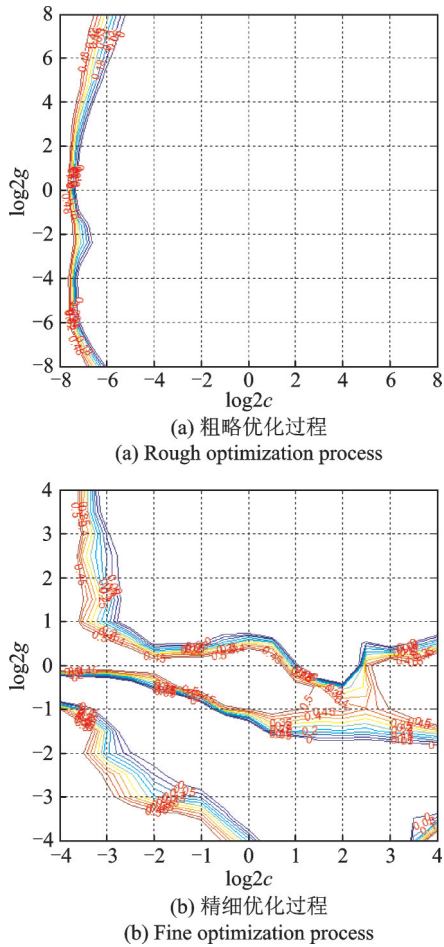


图3 参数粗略和精细优化过程

Fig.3 Rough and fine optimization of parameters

图3(a)为参数 c 和 g 的粗略优化过程:在 $2^{-8} \sim 2^8$ 中粗略得出 $c = 8.0314$, $g = 4.35897$, $MSE = 0.10992$,粗略确定了 c 和 g 的数据范围;图3(b)为精细优化过程:缩小范围在 $2^{-4} \sim 2^4$ 中查找 c 和 g ,最后得到最优的 c 和 g 为 $c_b = 6.0629$, $g_b = 2.2974$,并将其作为 SVM 此次运算的参数。使用5折交叉验证方法对并发故障进行诊断,并将故障诊断加过与故障模拟实验采集数据的故障记录对比得出故障命中率和虚警率。表3对比了5折交叉验证下经网格优化后使用的参数优化前后对并发故障的诊断结果。

由表3可知,选择默认设置($c=10, g=0.1$)时,制冷设备故障诊断的平均正确率为46.75%,MSE平均值为0.634;而使用优化得到的参数($c=6.0629, g=2.2974$)后,制冷设备故障诊断的正确率有了明显提高,而且每个折次下都有较高的正确率,平均正确率达到了96.80%,MSE平均值为0.027,证明该SVM模型对制冷设备故障诊断具有

表3 5折交叉验证下参数优化前后故障诊断结果

Tab.3 Fault diagnosis results before and after parameter optimization under 5-fold cross validation

折次	c	g	正确率/%	MSE
1	10	0.1	43.58	0.584
	6.0629	2.2974	97.98	0.012
2	10	0.1	47.97	0.691
	6.0629	2.2974	96.47	0.027
3	10	0.1	47.38	0.723
	6.0629	2.2974	96.14	0.037
4	10	0.1	45.67	0.547
	6.0629	2.2974	96.94	0.023
5	10	0.1	49.15	0.627
	6.0629	2.2974	96.47	0.035
平均结果	10	0.1	46.75	0.634
	6.0629	2.2974	96.80	0.027

较高的准确率。

4 信息融合

4.1 SVM模型与NFODCA模型对比

将测试集数据分别用支持向量机(SVM)模型和非完全正交指定元分析(NFODCA)模型诊断,各类故障命中率和虚警率对比如表4所示。

由表4可见,非完全正交指定元分析(NFODCA)和支持向量机(SVM)两种模型对制冷设备的故障均有较高的准确率,且两种方法对不同故障识别度不同,各自在不同类型故障的识别有一定优势。

4.2 加权证据理论信息融合

对于制冷装置的并发故障诊断,如果只采用单一的诊断结论,极易造成误诊。前面分别从非完全正交指定元分析(NFODCA)和支持向量机(SVM)两种模型研究了制冷设备的并发故障,如果采用多专家集成诊断的方式,将不同方法的诊断结论进行融合决策,那么将会大大提高制冷设备故障诊断结论的准确性和全面性^[12]。

文献[13]证明基于加权证据理论融合具有较好的聚焦能力,因此采用该方法对非完全正交指定元分析(NFODCA)和支持向量机(SVM)两种模型的诊断结果进行信息融合。将训练集中的每组数据视为一个证据组,将16种不同类型的制冷设备故障定义为一个空间 $\Theta = \{F_1, F_2, \dots, F_{16}\}$ 作为辨识框架, Θ 是由相互排斥的命题组成的有限完备集。 2^Θ 为 Θ 的幂

表 4 SVM和NFODCA模型对各类故障命中率和虚警率对比

Tab.4 Comparison of SVM and NFODCA models for various failure hit ratios and false alarm rates

故障类型	NFO	SVM	NFO	SVM
	DCA 命中率	命中率	DCA 虚警率	虚警率
d_1	98.94	95.93	0.27	0.39
d_2	98.07	97.04	0.29	0.40
d_3	94.56	97.37	0.37	0.26
d_4	94.59	96.67	0.56	0.31
d_5	97.37	97.92	0.29	0.34
d_6	96.36	95.18	0.32	0.52
d_1+d_3	99.21	95.64	0.25	0.76
d_1+d_6	98.48	95.65	0.89	0.67
d_2+d_5	97.94	98.35	0.74	0.48
d_3+d_4	95.65	98.63	0.92	0.43
d_3+d_6	95.67	97.42	0.39	0.94
d_4+d_5	97.65	94.67	0.24	0.68
d_5+d_6	95.57	98.12	0.67	0.33
$d_1+d_2+d_4$	97.37	94.38	0.42	0.87
$d_3+d_4+d_6$	98.33	98.64	0.38	0.44
$d_4+d_5+d_6$	95.33	97.21	0.74	0.25
平均结果	96.94	96.80	0.48	0.50

集,表示 Θ 所有子集的集合。在 2^Θ 上定义基本概率分配函数 $m:2^\Theta \subseteq [0, 1], m$ 满足下列条件

$$\begin{cases} m(\varphi) = 0 \\ \sum_{A \subseteq \Theta} m(A) = 1 \end{cases} \quad (11)$$

笔者采用了两种故障诊断方法,诊断结果中有两种待组合证据体 E_1, E_2 ,对应基本概率分配函数分别为 m_1, m_2 ,对应焦元分别为 A_i, B_j, A_i, B_j 的公共焦元为 C_i, m_1, m_2 之间的冲突程度系数为 K 。根据不同证据源的可靠程度分配权重系数,对相应故障敏感度较高的证据源赋以较高的权值,另一个模型赋以较低的权值,具体权值由多次实验后对比平均命中率和虚警率择优选出^[14]。设 E_1, E_2 的权重系数分别为 w_1, w_2 ,满足 $w_1 + w_2 = 1$,定义 N 个证据源对焦元的平均支持程度为

$$\bar{m} = \sum_{i=1}^N w_i m_i \quad (12)$$

基于保持 \bar{m} 恒定的原则,加权后的基本概率分配函数分别为 $m_1' = m_1; m_2' = 2\bar{m} - m_1$ 。使用公共焦元的概率平方和的占比将冲突程度系数 K 分配给对应的焦元,冲突分配系数 a_i 定义如下

$$a_i = \frac{\sum_{A_i \cap B_j = C_i} (m_1'^2(A_i) + m_2'^2(B_j))}{\sum (m_1'^2(A_i) + m_2'^2(B_j))} \quad (13)$$

因此,加权证据理论融合公式为

$$m'(C_i) = \begin{cases} \sum_{A_i \cap B_j = C} m_1'(A_i) m_2'(B_j) + a_i K & (C_i \neq \varphi, C_i \subset U) \\ 0 & (C_i = \varphi) \end{cases} \quad (14)$$

将NFODCA与SVM模型的证据体经上述方法融合后得到的故障诊断结果与故障模拟实验采集数据的故障记录对比,得出故障诊断命中率和虚警率如表5所示。由表5可以看出,制冷设备的故障识别结果经加权证据理论信息融合后更为精确,平均命中率达到99.10%,平均虚警率降低至0.21%。

表 5 信息融合后各类故障命中率和虚警率

Tab.5 Hit rate and false alarm rate of various faults after information fusion

故障类型	命中率	虚警率
d_1	99.54	0.17
d_2	99.28	0.21
d_3	98.64	0.19
d_4	98.67	0.24
d_5	99.23	0.18
d_6	98.54	0.22
d_1+d_3	99.86	0.17
d_1+d_6	99.32	0.28
d_2+d_5	99.92	0.24
d_3+d_4	99.07	0.31
d_3+d_6	98.65	0.21
d_4+d_5	98.79	0.18
d_5+d_6	99.64	0.16
$d_1+d_2+d_4$	98.53	0.27
$d_3+d_4+d_6$	99.59	0.20
$d_4+d_5+d_6$	98.38	0.14
平均结果	99.10	0.21

5 结 论

1) 非完全指定元分析(NFODCA)和支持向量机(SVM)两种数据挖掘方法在训练集无并发故障数据,仅在测试集中包含并发故障数据的条件下对制冷设备的故障诊断均有较高的准确率,表明这两种方法均具有对未知并发故障类型进行判断的能力。其中非完全正交指定元分析(NFODCA)的平均命中率达到96.94%,平均虚警率为0.48%;支

持向量机(SVM)的平均命中率达到96.80%,平均虚警率为0.50%。这两种方法对不同故障识别度不同,各自在不同类型故障的识别有一定优势。

2) 非完全正交指定元分析(NFODCA)和支持向量机(SVM)两种方法的故障识别结果经加权证据理论信息融合后,平均命中率提高了2.23%,平均虚警率降低了0.28%。说明这两种数据挖掘方法和信息融合技术结合应用后可以对制冷设备的并发故障得到更为准确的判断。

参 考 文 献

- [1] MACALISTER D, LAU Y. Air conditioning on equipment failures[J]. National Engineer, 2014, 3(9): 9-14.
- [2] SALVATORE S. Nonlinear model based on predictive control [J]. Manufacturing Technology, 2017, 5(9): 4-9.
- [3] FLORE L, KIM S. Case study of fault detection and diagnosis of a household air conditioner with a dynamic refrigeration cycle simulator [J]. Applied Thermal Engineering, 2016, 9(4): 35-37.
- [4] KUMAR P. DCA-SVM based automated fault diagnosis for compression refrigeration systems[J]. Journal of Mechanical Engineering, 2015, 16(3): 82-85.
- [5] 韩华, 谷波, 任能. 基于主元分析与支持向量机的制冷系统故障诊断方法[J]. 上海交通大学学报, 2011, 45(9): 1355-1361.
HAN Hua, GU Bo, REN Neng. Fault diagnosis method of refrigeration system based on principal component analysis and support vector machine[J]. Journal of Shanghai Jiao Tong University, 2011, 45(9): 1355-1361. (in Chinese)
- [6] 周福娜, 文成林, 陈志国, 等. 基于多尺度指定元分析的多故障诊断方法[J]. 南京航空航天大学学报, 2011, 43(S1): 91-96.
ZHOU Funa, WEN Chenglin, CHEN Zhiguo, et al. Multi-fault diagnosis method based on multi-scale designated cell analysis[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2011, 43(S1): 91-96. (in Chinese)
- [7] 李蔚, 俞芸萝, 盛德仁, 等. 基于动态数据挖掘的热力参数传感器故障诊断[J]. 振动、测试与诊断, 2016, 36(4): 694-699.
LI Wei, YU Yunluo, SHENG Deren, et al. The fault diagnosis of thermal parameter sensor based on dynamic data mining [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(4): 694-699. (in Chinese)
- [8] 黄海松, 魏建安. 基于不平衡数据样本特性的新型过采样SVM分类算法[J]. 控制与决策, 2018, 33(9): 1549-1558.
HUANG Haisong, WEI Jianan. New over-sampling SVM classification algorithm based on unbalanced data sample characteristics [J]. Control and Decision, 2018, 33(9): 1549-1558. (in Chinese)
- [9] SALSABURRY T. A temperature controller for refrigerator units based on simplified physical models [J]. Advanced Manufacturing Technology, 2018, 39(5): 342-365.
- [10] 杨宇飞, 袁卫星, 杨波, 等. 基于蒸气压缩制冷循环的便携式微环境冷却系统研究[J]. 航空学报, 2013, 34(11): 2500-2509.
YANG Yufei, YUAN Weixing, YANG Bo, et al. Research on portable micro-environment cooling system based on vapor compression refrigeration cycle [J]. Journal of Aeronautics, 2013, 34(11): 2500-2509. (in Chinese)
- [11] KATIPALMULA S. Automated diagnostics improving building system and equipment performance [J]. Energy News, 2016, 9(6): 145-152.
- [12] 孙丽萍, 李元, 张冬妍. 中央制冷空调冷冻水系统模糊RBF控制研究[J]. 电机与控制学报, 2017, 5(15): 110-116.
SUN Liping, LI Yuan, ZHANG Dongyan. Fuzzy RBF control of centralized refrigeration and air conditioning chilled water system [J]. Journal of Electric Machines and Control, 2017, 5(15): 110-116. (in Chinese)
- [13] 袁杰, 王福利, 王姝, 等. 基于D-S融合的混合专家知识系统故障诊断方法[J]. 自动化学报, 2017, 43(9): 1580-1587.
YUAN Jie, WANG Fuli, WANG Zhu, et al. Fault diagnosis method for hybrid expert knowledge system based on D-S fusion [J]. Journal of Automation, 2017, 43(9): 1580-1587. (in Chinese)
- [14] 李娟莉, 王健, 杨兆建. 基于三层信息融合的提升机制动系统故障诊断[J]. 振动、测试与诊断, 2018, 38(2): 407-412.
LI Juanli, WANG Jian, YANG Zhaojian. Fault diagnosis of mine hoist braking system based on three layers information fusion [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(2): 407-412. (in Chinese)



第一作者简介:周旖璿,女,1996年3月生,硕士生。主要研究方向为智能检测与控制。曾发表《基于MATLAB的拖拉机座椅悬架振动特性分析软件的开发》(《河北农机》2016年第7期)等论文。
E-mail:zhouyijun@njust.edu.cn