

应用粒计算的混合智能故障诊断技术研究

张周锁, 侯照文, 孙闯, 何正嘉

(西安交通大学机械工程学院, 710049, 西安)

摘要: 针对现有的混合智能故障诊断模型缺乏通用方法和混合框架, 未能实现不同智能诊断方法的实质性融合和优势互补的问题, 提出并构建了一种基于粒计算的混合智能故障诊断模型. 该模型的核心是在邻域粗糙集中求取不同的邻域值, 对故障特征集进行分层粒化, 在不同粒度下获得核属性集. 利用核属性集在相应粒度下构建人工神经网络和支持向量机子分类器, 通过评估矩阵算法对所有粒度下全部子分类器的诊断结果进行融合集成. 模型应用结果表明, 分类精度随着粒度层的增加而不断提高, 集成后的分类精度高于不同粒度下的所有子分类器, 从而体现了粒化分层的优势和不同智能诊断方法的优势互补, 为混合智能诊断提供了一种新途径.

关键词: 粒计算; 邻域粗糙集; 混合智能; 故障诊断

中图分类号: TH17; TP18 **文献标志码:** A **文章编号:** 0253-987X(2011)01-0048-06

Hybrid Intelligent Diagnosis Technology Based on Granular Computing

ZHANG Zhousuo, HOU Zhaowen, SUN Chuang, HE Zhengjia

(School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Aiming at lacking hybrid modes and common algorithms in existing hybrid intelligent diagnosis, a new model of hybrid intelligent fault diagnosis based on granular computing is proposed. In the model, the core features sets (CFS) are extracted in different granular levels by the reduction algorithm based on neighborhood rough set, then, CFS are chosen to train artificial neural network and support vector machines as sub-classifiers in corresponding levels. And the results of sub-classifiers in different granular levels are combined by criterion matrix algorithm as output of hybrid intelligent diagnosis. The model is applied to fault diagnosis of roller bearings in high-speed locomotive. The application results demonstrate that the classification accuracy is raised with the increasing granular levels, and the accuracy of hybrid results is higher than the one of any sub-classifier. The proposed model exhibits the effect of granulation and the advantages complementation among different intelligent methods to provide a new way for hybrid intelligent diagnosis.

Keywords: granular computing; neighborhood rough set; hybrid intelligence; fault diagnosis

智能诊断方法是提高诊断精度和效率的重要手段, 人工神经网络、专家系统、支持向量机等不同的智能诊断方法已经被应用于工程实际中, 并取得了成效. 这些方法各有特点和优缺点^[1-2], 为了使不同的智能诊断方法能够优势互补, 提出了混合智能诊断技术, 并成为研究热点^[3-4]. 为了进一步研究混合

智能故障诊断的通用方法和混合框架, 本文提出了基于粒计算的混合智能故障诊断新模型. 粒计算是一种信息处理的新方法^[5], 利用其在不同粒度下综合分析解决复杂问题的多分辨和集成思想, 有望实现不同智能诊断方法间的优势互补, 为混合智能诊断提供了一种新途径.

作为粒计算的模型之一,粗糙集已经被应用于智能决策、数据挖掘等领域^[6].它首先由 Pawlak^[7]提出,随后人们又提出了邻域模型的概念,将粗糙集推广至数值型数据处理^[8-9].2008年,胡清华等人^[10]提出了邻域粒化及邻域粗糙集属性约简处理数值型属性的新方法.

本文利用邻域粗糙集在属性约简以及粒化分层方面的特点,提出了基于邻域粗糙集的混合智能故障诊断模型(HIDM).该模型的核心在于利用邻域粗糙集进行属性集约简和粒化,在不同的粒度下构建不同的子分类器,通过评估矩阵算法,集成不同粒度下各层次子分类器的输出,从而得到混合智能的诊断结果.

1 基于邻域粗糙集的属性约简和粒化

1.1 邻域粗糙集的基本概念

对于论域 U 中的元素 x_i ,定义 x_i 的 δ 邻域为

$$\delta(x_i) = \{x \mid x \in U, d(x, x_i) \leq \delta\} \quad (1)$$

其中 d 为距离函数,对于 $\forall x_1, x_2, x_3 \in U, d(x_1, x_2) \geq 0$, 当且仅当 $x_1 = x_2$ 时, $d(x_1, x_2) = 0$; $d(x_1, x_2) = d(x_2, x_1)$; $d(x_1, x_3) \leq d(x_1, x_2) + d(x_2, x_3)$.

对于二维实数空间,基于 1、2 范数和无穷范数的邻域分别为菱形、圆形和正方形区域, δ 即为所取邻域值.因此,当选择不同大小邻域值时,论域就可以相应地被划分为不同的粒度层.为了方便讨论对论域的粒化,定义集合 A_1 包含于 A_2 的强度函数为

$$I(A_1, A_2) = \frac{\text{Card}(A_1 \cap A_2)}{\text{Card}(A_1)}, \quad A_1, A_2 \neq \emptyset \quad (2)$$

式中:Card 表示求集合的基数.当 $A_1 = \emptyset$ 时,规定 $I(A_1, A_2) = 0$, 则 $0 \leq I(A_1, A_2) \leq 1$.

设集合 X 为论域 U 的非空子集,类似于传统粗糙集, X 的可变精度下近似集和上近似集分别为

$$\underline{N}_X^k = \{x_i \mid I(\delta(x_i), X) \geq k, x_i \in U\} \quad (3)$$

$$\overline{N}_X^k = \{x_i \mid I(\delta(x_i), X) \geq 1 - k, x_i \in U\} \quad (4)$$

式中: k 为可变精度, $k \geq 0.5$. X 的近似边界为

$$B_N(X) = \overline{N}_X - \underline{N}_X, \quad \forall X \in U, \overline{N}_X \supseteq X \supseteq \underline{N}_X$$

1.2 邻域基点的获取

邻域粗糙集粒化属性的关键在于选择多个合适的 δ , 在相应 δ 下得到不同层次的核属性集.因此,需要评估特征之间的欧式距离来确定一个 δ 作为邻域基点,再在这个基点下选择不同大小的 δ .

设 $S = (U, A, V, f)$ 是一个数值型信息系统,其中 A 为属性的非空有限集合; $V = \bigcup_{a \in A} V_a$, V_a 为属性 a 的值域; f 是一个信息函数,它为论域中的每个对象的属性赋予信息值.设 P 为属性子集,则由 P 确定的欧式距离矩阵中的元素为

$$G_{ij} = d(x_i, x_j) = \left(\sum_{l=1}^{|P|} (f(x_i, a_l) - f(x_j, a_l))^2 \right)^{1/2} \quad (5)$$

用 G_m 表示 $d(x_i, x_j)$ 的最大值,令

$$G'_{ij} = \frac{d(x_i, x_j)}{G_m} \quad (6)$$

则可获得邻域基点值

$$\delta_2 = \frac{1}{|U|^2} \sum_{i,j=1}^{|U|} G'_{ij} \quad (7)$$

两侧邻域值为

$$\delta_1 = \delta_2 - r; \quad \delta_3 = \delta_2 + r$$

式中: r 为邻域半径.结合文献[10]中对 δ 的统计, r 应在 $[0.0, 0.1]$ 之间选择.

1.3 基于邻域粗糙集的属性约简和粒化算法

分别在 3 个邻域值下对提取到的属性集进行约简,提取核属性集.给定一个邻域决策系统 $N_{DT} = \langle U, A, D \rangle$, 对于 $B \subseteq A$, D 对 B 的依赖度为 $\gamma_B(D) = \text{Card}(\underline{N}_B^D) / \text{Card}(U)$.由此在 $N_{DT} = \langle U, A, D \rangle$ 中定义 a 相对于 B 的重要度为

$$S_{IG}(a, B, D) = \gamma_{B \cup a}(D) - \gamma_B(D) \quad (8)$$

基于属性重要度指标,在一定邻域值下构造贪心式属性约简算法^[10].基于邻域粗糙集的特征属性选择算法为:

Input: $N_{DT} = \langle U, A, D \rangle$;

Output: 约简 red.

第 1 步: $\forall a \in A$: 计算邻域关系 N_a ;

第 2 步: $\emptyset \rightarrow \text{red}$;

第 3 步: 对任意 $a_i \in A - \text{red}$

计算 $S_{IG}(a_i, \text{red}, D) = \gamma_{\text{red} \cup a_i}(D) - \gamma_{\text{red}}(D)$, //

此处定义 $\gamma_{\emptyset}(D) = 0$.

第 4 步: 选择 a_k , 其满足:

$$S_{IG}(a_k, \text{red}, D) = \max_i (S_{IG}(a_i, \text{red}, D))$$

第 5 步: 如果 $S_{IG}(a_k, \text{red}, D) > 0$,

$\text{red} \cup a_k \rightarrow \text{red}$

返回到第 3 步;

否则,将 red 作为属性约简结果,迭代结束.

该算法以空集为起点,每次计算全部剩余属性的重要度,从中选择属性重要度最大的属性加入约简集合,直到所有剩余属性的重要度为0,即加入任何新的属性时,系统的依赖性函数值不再发生变化为止。

利用依次从大到小的3个邻域值 δ_1 、 δ_2 、 δ_3 ,通过特征属性选择算法,可以对应求得3层粒度下的核属性集CFS1、CFS2和CFS3.利用这些核属性集可在3层不同粒度下,构建不同种类的子分类器。

2 基于评估矩阵的集成算法

为了使不同粒度下不同种类子分类器能够实现优势互补,利用基于评估矩阵的集成算法对这些子分类器的分类结果进行集成融合。

采用训练样本统计每个子分类器的识别情况,形成第 k 个子分类器识别情况的混淆矩阵为

$$\mathbf{C}_k = \begin{bmatrix} n_{11}^{(k)} & \cdots & n_{1M}^{(k)} \\ \vdots & & \vdots \\ n_{M1}^{(k)} & \cdots & n_{MM}^{(k)} \end{bmatrix}, k = 1, 2, \dots, K \quad (9)$$

式中: K 为子分类器的个数; M 表示故障种类; $n_{ij}^{(k)}$ 表示第 k 个子分类器将 j 类中的样本识别为 i 类的数量.其含义为:①如果 $i=j$,表示第 k 个子分类器正确识别 i 类中样本的数量;②如果 $j \neq i$,表示第 k 个子分类器将 j 类中的样本错误识别为 i 类的数量.对于第 k 个子分类器,识别结果为 j 的样本总数为

$$n_j^{(k)} = \sum_{i=1}^M n_{ij}^{(k)}, j = 1, 2, \dots, M \quad (10)$$

在 k 个子分类器的识别结果为 $j=k(x)$ 的条件下,样本来自 i 类的概率可用条件概率表示为

$$P(x \in i | k(x) = j) = n_{ij}^{(k)} / n_j^{(k)} = n_{ij}^{(k)} / \sum_{i=1}^M n_{ij}^{(k)} \quad (11)$$

将 $\mathbf{C}_k$ 作为分类器组合时的先验知识,即以条件概率作为第 k 个子分类器对 i 类故障的诊断性能指标,则混合模型对 i 类故障的诊断性能为

$$P_H(x \in i) = \sum_{k=1}^K P(x \in i | k(x) = j) \quad (12)$$

若

$$P_H(x \in h) = \max P_H(x \in i), h = 1, 2, \dots, M \quad (13)$$

则评估矩阵的混合模型对 x 样本的诊断输出为

$H_R(x) = h$.设有6种故障,通过训练2种分类器分别构建了2个混淆矩阵,即

$$\mathbf{C}_1 =$$

$$\begin{bmatrix} 0.4706 & 0.3571 & 0.0000 & 0.0000 & 0.1429 & 0.0000 \\ 0.4118 & 0.5000 & 0.0000 & 0.0000 & 0.0000 & 0.0000 \\ 0.0000 & 0.0000 & 0.7778 & 0.0000 & 0.0000 & 0.0000 \\ 0.0588 & 0.0715 & 0.0000 & 1.0000 & 0.0000 & 0.0000 \\ 0.0588 & 0.0714 & 0.0000 & 0.0000 & 0.8571 & 0.3750 \\ 0.0000 & 0.0000 & 0.2222 & 0.0000 & 0.0000 & 0.6250 \end{bmatrix}$$

$$\mathbf{C}_2 =$$

$$\begin{bmatrix} 0.5882 & 0.2000 & 0.0000 & 0.0000 & 0.0909 & 0.0588 \\ 0.1765 & 0.7000 & 0.0000 & 0.0667 & 0.2727 & 0.0000 \\ 0.0000 & 0.0000 & 1.0000 & 0.0000 & 0.0000 & 0.0000 \\ 0.0000 & 0.1000 & 0.0000 & 0.9333 & 0.0000 & 0.0000 \\ 0.2353 & 0.0000 & 0.0000 & 0.0000 & 0.6364 & 0.1176 \\ 0.0000 & 0.0000 & 0.0000 & 0.0000 & 0.0000 & 0.8235 \end{bmatrix}$$

$\mathbf{C}_1$ 和 $\mathbf{C}_2$ 对角线的值均为正确分类的概率,如 $\mathbf{C}_1$ 中第1行第1列的0.4706表示分类器1将第1种故障正确分类的概率为47.06%,而矩阵中的其他值表示错分的概率.如 $\mathbf{C}_1$ 中第1行第2列中的0.3571表示分类器1将第2种故障错分为第1种故障的概率为35.71%。

假设分类器1对一个未知样本的诊断为第3种故障,而分类器2对未知样本诊断为第2种故障,根据混合算法,将 $\mathbf{C}_1$ 中第3列和 $\mathbf{C}_2$ 中第2列进行合并,得到单列矩阵,转置后得到 $[0.2, 0.7, 0.7778, 0.1, 0, 0.2222]$.合并后第3种故障的评估值为最大值0.7778,因此混合模型最终诊断该样本为第3种故障。

3 混合智能诊断模型的构建

鉴于邻域粗糙集粒化分层的特点,本文提出了一种基于邻域粗糙集的混合智能诊断模型(见图1).该模型的核心内容为基于特征欧氏距离来求取 δ_1 、 δ_2 、 δ_3 ,利用邻域粗糙集粒化约简算法分别在这3个邻域值下获得对应的CFS1、CFS2和CFS3.利用CFS1、CFS2和CFS3分别在3层粒度下构建广义回归神经网络模型(GRNN1, GRNN2, GRNN3),以及一对一多分类支持向量机分类器(SVMS1, SVMS2, SVMS3),并得到6个子分类器.通过评估矩阵混合算法集成融合6个子分类器的分类结果,




图 1 混合智能诊断模型的流程图

得到最终的混合智能诊断结果。

4 混合智能模型在机车轴承诊断中的应用

4.1 实验台介绍与数据采集

以某客运高速电力机车的滚动轴承为诊断对象,利用混合智能诊断模型对其运行状态进行识别,轴承测试实验台如图 2 所示。




图 2 轴承测试的实验装置

将被测试的滚动轴承安装在一个液压驱动的实验台架上,采用 Sony EX 数据采集与分析系统记录轴承的加速度信号幅值 a ,轴承的实验参数如表 1 所示. 采集的数据集包括 7 个子集,每种子集对应一种故障状态(包括正常),共 203 个数据样本. 其中, 105 个样本用于训练,98 个样本用于测试. 轴承的 7 种状态如表 2 所示,轴承加速度信号的时域波形如图 3 所示。

表 1 滚动轴承的实验参数

轴承型号	552732QT
载荷/N	9 800
内圈直径/mm	160
外圈直径/mm	290
滚动体直径/mm	34
滚动体个数	17
接触角/(°)	0
转速/r · min ⁻¹	480~640
采样频率/kHz	12.8
采样长度	8 192

表 2 滚动轴承的状态

状态标记	状态类型	样本数目
1	正常	29
2	外圈故障	29
3	内圈故障	29
4	滚动体故障	29
5	外圈及内圈复合故障	29
6	外圈及滚动体复合故障	29
7	外圈、内圈及滚动体复合故障	29




图 3 故障信号的时域波形图

4.2 故障特征提取与特征集的分层粒化约简

采用 10 阶 Daubechies 离散正交小波 db10 对采集的振动信号进行 3 层小波包分解,得到了 8 个频带的时域分解信号,并分别提取这些信号的 6 个时域特征和 13 个频域特征. 由 152 个特征组成特征集,通过欧氏距离特征评估技术求得 $\delta_2=0.099\ 16$. 设 $r=0.05$,可求得 $\delta_1=0.049\ 16, \delta_3=0.149\ 16$.

利用基于邻域粗糙集的属性约简和粒化算法对特征集进行粒化分层和约简,求取核属性集.当 δ 为 0.049 16 时,第 1 次迭代计算的特征重要度如图 4 所示.选择每次迭代时重要度的最大特征加入核属性中,直至剩余特征的重要度为 0 时,即获得核属性集.其中,第 1 层邻域经过 6 次迭代、第 2 层邻域经过 8 次迭代、第 3 层邻域经过 13 次迭代后,获得的核属性集如表 3 所示.




图 4 第 1 次迭代计算的特征重要度

表 3 3 层邻域下的核属性集

粒化层	δ	核属性集的特征序号
1	0.049 16	132,60,85,72,15
2	0.099 16	93,145,65,85,60,137,28
3	0.149 16	64,93,10,125,2,137,60,85,112,27,73,45

4.3 子分类器的构建及其分类结果的集成融合

利用训练样本的核属性集对 3 层粒度下的 2 种智能子分类器进行训练,构建了不同粒度下的 6 个子分类器.经过优选获得 2 种子分类器的参数为:一对一多分类支持向量机的惩罚因子 $c=10\ 000$,不敏感损失因子 $\epsilon=0.01$;核函数为多项式核函数,其阶数 $d=2$;广义回归神经网络的平滑参数 $s=2$.

通过评估矩阵算法,对不同粒度下 6 个子分类器的分类结果进行融合,得到的混合智能诊断模型最终的诊断结果如表 4 所示.图 5 是核属性集的分类精度柱状图,从 2 种分类器的分类效果中可看出,在支持向量机方面,用核属性集构建时获得了 89.46% 的平均测试精度,比随机属性集构建时高 35.06%.在 GRNN 神经网络方面,用核属性集构建时获得了 76.53% 的平均测试精度,比随机属性集构建时高 34.86%.从不同层次分类效果上来看,第 1 层邻域的平均测试分类精度为 67.35%,第 2 层邻域的平均测试分类精度为 86.74%,第 3 层邻域的平均测试分类精度为 94.90%.可以看出,测试精度

随着粒化层的递增不断提高,最终由核属性集构建的混合模型获得了 97.96% 的最高测试精度.

表 4 电力机车实验台的故障分类结果 %

分类器及模型	核属性集		随机属性集	
	训练精度	测试精度	训练精度	测试精度
SVMS1	93.33	78.57	47.63	51.06
SVMS2	100.00	93.88	49.55	55.02
SVMS3	100.00	95.92	54.67	57.13
GRNN1	63.81	56.12	58.64	23.41
GRNN2	80.95	79.59	65.34	49.56
GRNN3	91.43	93.88	72.36	52.04
HIDM	100.00	97.96	85.33	71.45




图 5 故障的分类精度柱状图

5 结 论

本文研究了基于邻域粗糙集的故障特征属性的约简和粒化算法,以及基于评估矩阵的子分类器分类结果的集成融合算法,建立了基于邻域粗糙集的混合智能诊断模型,并将该模型应用于电力机车轮对轴承故障的分类中.结果表明:分类精度随着故障特征属性粒化的粒度层的递增而不断提高,体现了粒化的效果.混合集成后的分类精度高于不同粒度下不同种类的所有单个子分类器的分类精度,体现了不同智能诊断方法的优势互补.

本文提出的混合智能诊断模型实现了支持向量机和神经网络的有效融合,在此基础上还可以进一步研究更多种智能分类器的融合方法.模型中包含的粒化并集成的思想为混合智能诊断提供了新途径,具有广阔的应用前景.

参考文献:

[1] HAM F M, KOSTANIC I. Principles of neurocom-

- puting for science & engineering [M]. New York, USA: McGraw Hill, 2001.
- [2] WEI L L, LONG W J, ZHABG W X. Fuzzy data domain description using support vector machines [J]. IEEE Transactions on Machine Learning and Cybernetics, 2003(5): 3082-3085.
- [3] SAMPATH S, SINGH R. An integrated fault diagnostics model using genetic algorithm and neural networks [J]. ASME Journal of Engineering for Gas Turbines and Power, 2006, 128(1): 49-56.
- [4] GUO H, JACK L B, NANDI A K. Feature generation using genetic programming with application to fault classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, 2005, 35(1): 89-99.
- [5] 苗夺谦, 王国胤, 刘清, 等. 粒计算: 过去、现在与展望 [M]. 北京: 科学出版社, 2007.
- [6] WANG Guoyin. Algebra view and information view of rough sets theory [C]// Data Mining and Knowledge Discovery: Theory, Tools, and Technology. Bellingham, USA: The International Society for Optical Engineering, 2001: 200-207.
- [7] PAWLAK Z. Rough sets-theoretical aspects of reasoning about data [M]. Dordrecht, Holland: Kluwer Academic, 1991.
- [8] LIN T, GRANULAR Y. Computing on binary relations: data mining and neighborhood systems [C]// Proc of the Rough Sets in Knowledge Discovery. New York, USA: Springer-Verlag, 1998: 107-121.
- [9] WU Weizhi, ZHANG Wenxiu. Neighborhood operator systems and approximations [J]. Information Sciences, 2002, 144(1/4): 201-217.
- [10] 胡清华, 于达仁, 谢宗夏. 基于邻域粒化和粗糙逼近的数值属性约简[J]. 软件学报, 2008, 19(3): 640-649.
- HU Qinghua, YU Daren, XIE Zongxia. Numerical attribute reduction based on neighborhood granulation and rough approximation [J]. Journal of Software, 2008, 19(3): 640-649.

[本刊相关文献链接]

- 基于约束总体最小二乘算法的接地网故障诊断新模型. 西安交通大学学报, 2010, 44(10): 110-115.
- 机车故障诊断的局域均值分解解调方法. 西安交通大学学报, 2010, 44(5): 40-44.
- 利用非线性流形学习的轴承早期故障特征提取方法. 西安交通大学学报, 2010, 44(5): 45-49.
- 滚动轴承故障诊断的多小波谱峭度方法. 西安交通大学学报, 2010, 44(3): 77-81.
- 一种自适应局部线性嵌入与谱聚类融合的故障诊断方法. 西安交通大学学报, 2010, 44(3): 77-82.
- 粒计算及其在机械故障智能诊断中的应用. 西安交通大学学报, 2009, 43(9): 37-41.
- 具有模糊隶属度的模糊支持向量机算法. 西安交通大学学报, 2009, 43(9): 40-43.
- 自适应移频变尺度随机共振在故障诊断中的应用. 西安交通大学学报, 2009, 43(7): 69-73.
- 气动阀间歇性排气噪声辐射规律的研究. 西安交通大学学报, 2008, 42(9): 1091-1095.
- 运用电路蕴涵及拓扑信息提高数字电路故障压缩效率. 西安交通大学学报, 2008, 42(8): 958-962.
- 免疫编程的故障特征构造方法. 西安交通大学学报, 2007, 41(9): 1036-1039.
- 基于支持向量机的发动机故障诊断. 西安交通大学学报, 2007, 41(9): 1124-1126.
- 支持向量机在电力变压器故障诊断中的应用. 西安交通大学学报, 2007, 41(6): 722-726.
- 基于支持向量域描述的多故障诊断动态模型. 西安交通大学学报, 2007, 41(5): 593-597.
- 人眼视觉特性与粗糙集结合的 X 射线图像增强算法. 西安交通大学学报, 2009, 43(6): 48-51.
- 一种基于分辨函数的属性约简算法及其应用. 西安交通大学学报, 2008, 42(12): 1455-1458.
- 粗糙集属性约简判别分析方法及其应用. 西安交通大学学报, 2007, 41(8): 939-943.
- 粗糙集高效遗传约简算法. 西安交通大学学报, 2007, 41(4): 444-447.

(编辑 管咏梅)