

粗糙集 CMAC 神经网络故障诊断策略

冯远静 李良福 冯祖仁

(西安交通大学系统工程研究所, 陕西 西安 710049)

摘要 提出一种基于粗糙集 CMAC 神经网络的智能互补融合的诊断策略. 该策略利用粗糙集理论对数据样本进行数据浓缩, 提取初步的诊断规则. 对初步的诊断规则通过神经网络进行粗映射, 利用神经网络的分类逼近能力, 建立故障状态空间到诊断空间的精确映射. 大大提高了神经网络的收敛速度和逼近精度. 将该神经网络应用于的变压器故障诊断实例, 结果表明, 该神经网络具有分类逼近能力强, 计算量小等优点. 诊断正确率比普通神经网络的诊断正确率高.

关键词 粗糙集, 神经网络, 故障诊断, 变压器

中图分类号 TP 277: TP 183

文献标识码 A

为了解决复杂的故障诊断问题, 人们常常采用模糊理论^[1]、专家系统^[2]、人工神经网络(ANN)^[3, 4]等智能方法. 其中人工神经网络. 它在故障诊断方面得到成功的应用. 但是对于样本数据量大, 强非线性性的情况, 往往不能达到满意的结果. 为了更好的解决普通神经网络故障诊断存在的问题, 本文将 RS 和小脑模型(CMAC) 神经网络结合起来. 利用 RSDA 从数据中提取出规则, 根据输入确定输出可能的子空间, 再在这些子空间上通过 CMAC 进行定量的逼近. 利用粗糙集理论, 从样本数据中约简冗余数据, 获取故障诊断知识, 形成一系列计算规则. 利用神经网络的强大的学习能力和数值逼近能力, 智能诊断故障原因.

1 粗糙集理论

在粗糙集中, 知识被理解成对于对象的分类能力. 设 $S = (U, A, V, f)$ 为一知识表达系统, $A = C \cup D$, $C \cap D = \Phi$, C 为条件属性集, D 为决策属性集, $A = \bigcup_{a \in A} V_a$ 为属性值域, f 为决策函数. 在粗糙集中, 知识的不确定性是通过边界的含糊性来表达的.

$x, y \in U$, 对于 $\Omega \in A$, R 是论域 U 上的一个等价关系. 如果满足 $xRy \Leftrightarrow (\forall q \in \Omega) (f_q(x) = f_q(y))$, 则称 R 是 x, y 的一个不可辨关系. 对于每个决策类 $X \in U$, 都可以有一个二元组 (RX, \bar{RX}) 来表示, 其中 RX, \bar{RX} 分别表示 R 下近似和 R 上近似, 即

$$RX = \{ x \in X : R(x) \subseteq X \}, \quad \bar{RX} = \bigcup_{x \in X} R(x).$$
 (1)

通过使用不可分辨关系, 定义元素对集合 X 的粗糙隶属函数为

$$\mu_X(x) = \frac{| X \cap RX |}{RX}.$$
 (2)

显然 $0 \leq \mu_X(x) \leq 1$. $\theta, \Phi \in A$ 如果等价关系 P 定义的每一个等价类都属于等价关系 Q 定义的等价类, 则称 θ 依赖于 Φ 依赖关系记作 $\theta \rightarrow \Phi$, 表示如下规则.

假设 $\theta = \{ \theta_1, \theta_2, \dots, \theta_n \}$, $\Phi = \{ \Phi_1, \Phi_2, \dots, \Phi_n \}$, 对于每一个 $t = \{ t_1, t_2, \dots, t_n \}$, 有唯一的决定 $s = \{ s_1, s_2, \dots, s_k \}$. 其中 $t_i \in V_{\theta_i}, s_i \in V_{\Phi_i}$. 即 $(\forall x \in U) [f(x, \theta_1) = t_1, \dots, f(x, \theta_n) = t_n] \Rightarrow f(x, \Phi_1) = s_1, \dots, f(x,$

收稿日期 2003- 12- 23

作者简介 冯远静(1977-), 男, 博士研究生, 主要从事智能系统和故障诊断的研究. E mail: fyj@mailst. xjtu. edu. cn

基金项目 国家自然科学基金资助项目(60175015)

$\Phi_k)=s_k]$.

利用 RSDA 的化简方法, 从原始数据中提取出 m 条 $\theta \rightarrow \Phi$ 规则, 第 i 条规则 r^i 为

$(f(x, \theta_1)=t_1^i, \dots, f(x, \theta_n)=t_n^i) \Rightarrow f(x, \Phi_1)=s_1^i, \dots, f(x, \Phi_k)=s_k^i, \quad i=1, 2, \dots, m.$

对于一组输入 $X=\{x_1, x_2, \dots, x_n\}$, 定义函数

$$g_i(j)=\begin{cases} 1, & x_j=t_j^i, \\ 0, & \text{其它}, \end{cases} \quad k=1, 2, \dots, n, \quad i=1, 2, \dots, m, \quad \lambda_i=\frac{1}{n}\sum_{j=1}^n g_i(j). \tag{3}$$

对于第 i 条规则第 j 个属性相对于等价类 X 的粗糙隶属函数为

$$\mu_X^i(t_j^i)=|X \cap R[t_j^i]|/|R[t_j^i]|. \tag{4}$$

基于粗糙集的规则提取有如下过程. 根据训练集进行编码构造信息决策系统信息决策系统简约计算, 条件属性集为 A , 决策属性为 D . (1) 初始化 $m=1, i=1, k=1$. (2) 利用某种等价关系对 A 和 D 进行划分, 记作 $R(A)=\{A_1, A_2, \dots, A_M\}, R'(D)=\{D_1, D_2, \dots, D_K\}$. (3) 取出 A_m , 计算其对论域的划分 $P(A_m)=\{B_1, B_2, \dots, B_l\}$. (4) 取出 D_k . (5) 计算决策规则适用度, $\mu_{D_k}(B_i)=|D_k \cap B_i|/|B_i|$. (6) $i=i+1$, 当 $i \leq l$ 时, 至(5). 否则当 $k < K$ 时, $k=k+1, i=1$, 至(3). 当 $k=K$ 时, 至(7). (7) 退出.

2 基于规则提取的 CMAC 网络

2.1 CMAC 的原理

小脑模型关联控制器(CMAC)^[5,6], 是 Albus 根据小脑的生物模型提出的一种人工神经网络. CMAC 具体的实现思想是将输入空间 S 划分为许多子空间, 每相邻的子空间互有重叠. S 中的各个输入向量在接受场函数的作用下, 落入相应的子空间. 每个子空间通过上述两个映射激活存储单元, 这些单元存储的权值叠加产生 CMAC 的输出. 普通 CMAC 利用 3 个序贯的映射 $S \xrightarrow{\alpha} A \xrightarrow{W} R$. S 是输入空间, A 是联想空间, W 是权重空间, R 是输出空间. (1) $S \xrightarrow{\alpha} A$: 对于输入向量 $s=(s_1, s_2, \dots, s_n)$, 映射算法为

$$C_i=\text{round}((s_i/s_{\max}) \cdot (L_i-1))+1, \quad i=1, 2, \dots, n, \tag{5}$$

其中 $s_{\max}=\max(s_1, s_2, \dots, s_n), L_i$ 为 s_i 的个数. $\alpha \in A$ 只有少数元素为 1, 大部分元素为 0. 输入空间中的一个点对应于 α 中的几个元素为 1. 该非线性映射在设计网络时就确定的. (2) $A \xrightarrow{W} R$: 如果联想空间中 α 的元素为 1, 则相连接的权 ω 就被“激活”. (3) $W \xrightarrow{R} R$: 对于输出 $y \in R$ 可以表示为 $y=\alpha^T \omega$.

2.2 基于规则提取 CMAC 网络结构

根据粗糙集规则提取算法和 CMAC 的原理, 我们给出了基于规则提取的 CMAC 网络结构, 如图 1 所

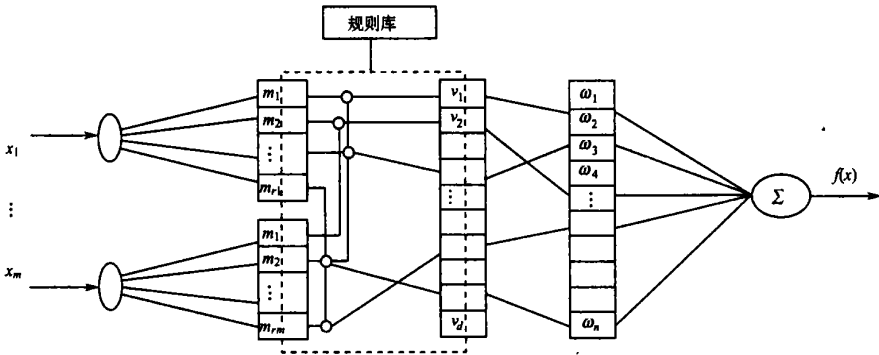


图1 基于规则提取的 CMAC 模型结构图

示. 网络共有 4 层构成, 其映射为如下算法. (1) $S \xrightarrow{\alpha} A$ 从输入空间到联想空间的映射. 第 1 层 输入层, 表示输入 $x=(x_1, x_2, \dots, x_m)^T$. 第 1 层共有 m 个节点, 第 i 个节点对应输入向量的第 i 个分量 x_i . 第 2 层 分别将 m 个输入量 (x_1, x_2, \dots, x_m) 离散化后, 按照某种不可辨关系进行划分, 得到 r_i 个不同的值. 可以定义该层神经元的作用函数为 Gauss 函数, 即

$$m_{ij}^j=e^{-\left(\frac{x_i-c_j}{\sigma_j}\right)^2}. \tag{6}$$

或者根据要求定义作用函数. 其中, $i=1, 2, \dots, m; j=1, 2, \dots, r_i$. 该层的输出为 m_{ij}^j . 第 3 层根据粗糙集数

据分析理论, 我们将 CMAC 网络的输入作为信息决策系统的条件属性, 网络输出离散后作为信息决策系统的决策属性. 该层的 $\alpha_l = \min(m_i, \dots, m_c)$, $l = 1, 2, \dots, R$; $i(, \dots, c) = 1, 2, \dots, r_1(, \dots, r_m)$. 其中 $R = \prod_{i=1}^m r_i$. 根据粗糙集理论规则提取算法, 计算每条规则的适用度 μ_l . 如果规则的适用度 $\mu_l \geq \gamma$, 则该节点的输出为: $u_l = \alpha_l \cdot \mu_l$, 其中 γ 为选定的常数. 否则删除该节点. (2) $A \rightarrow W$. 第 4 层对于选定的 L 条规则, 激活相连接的权空间 w_i , $i = 1, 2, \dots, L$. (3) $W \rightarrow R$. $y = \sum_{i=1}^L \omega_i u_i$.

2.3 学习算法

在这一层中, 只有被激活的 k 个神经元的连接权 ω_k 得到修正 ($i = 1, 2, \dots, k$). 这里的学习算法采用了 BP 算法. 当网络输入为 x 时, 设 y 为神经网络的实际输出, y_d 为相应的期望输出. 考虑如下误差目标函数为

$$E_p = \frac{1}{2} (y - y_d)^2,$$

7

从而

$$\frac{\partial E_p}{\partial \omega_k} = \frac{\partial E_p}{\partial y} \frac{\partial y}{\partial \omega_k} = - (y - y_d) v_i, \quad \omega_k(k+1) = \omega_k(k) - \beta \frac{\partial E_p}{\partial \omega_k}.$$

8

3 基于粗糙集神经网络的变压器故障诊断

3.1 基于粗糙集理论的变压器故障诊断信息系统

根据长期实践和对大量统计数据进行分析, 人们总结出一些利用故障产生的特征气体进行变压器故障诊断的方法. 其中利用 CH₄, H₂, C₂H₂, C₂H₆ 和 C₂H₄ 等 5 种气体间的比值来判断故障性质的方法, 经实践表明, 是一种变压器故障诊断的有效方法^[8]. 如某些故障变压器的色谱数据, 如表 1 所示. 根据粗糙集理论构建变压器故障诊断信息系统, 条件属性值为 CH₄/H₂, C₂H₆/CH₄, C₂H₄/C₂H₆ 和 C₂H₂/C₂H₄ 这 4 对气体的比值. 决策属性为诊断结果, 如表 2 所示.

表 1 变压器色谱数据(μL·L⁻¹)

样本	H ₂	CH ₄	C ₂ H ₆	C ₂ H ₄	C ₂ H ₂
1	170.0	330.0	77.0	430.0	13.0
2	81.0	130.0	74.0	230.0	2.9
3	130.0	440.0	180.0	730.0	0
4	30.0	110.0	137.0	52.0	22.2
...

表 2 粗糙集故障诊断信息系统

样本	CH ₄ /H ₂	C ₂ H ₆ /CH ₄	C ₂ H ₄ /C ₂ H ₆	C ₂ H ₂ /C ₂ H ₄	论断
1	0.997	0.851	0.725	0.959	局部放电-电晕 (有爬电痕迹)
2	0.898	0.674	0.512	0.982	连续放电
3	0.265	0.753	0.608	1.000	裸金属过热
4	0.146	0.422	0.084	0.552	正常
...

3.2 基于粗糙集神经网络的变压器故障诊断实例

选取实际结论比较明确的 821 台次的故障变压器的色谱数据, 作为原始故障样本集. 4 个比值属性的表示: a 为 CH₄/H₂, b 为 C₂H₆/CH₄, c 为 C₂H₄/C₂H₆, d 为 C₂H₂/C₂H₄. 将比值数据分为 4 个等级, 分别用代号 0, 1, 2, 3 表示. e 为诊断结果, 故障类型的表示: 1 为正常, 2 为局部放电(电晕), 3 为过热(< 150), 4 为过热(150~ 200), 5 为过热(200~ 300), 6 为裸金属过热, 7 为线圈有环流, 8 为铁心和箱壳有环流或接头过负荷, 9 为电弧放电(无贯穿), 10 为电弧放电(贯穿), 11 为连续的放电, 12 为局部放电-电晕(有爬电痕迹). 将 4 个比值属性作为粗糙集信息系统的条件属性, 将诊断结果作为信息系统的决策属性. 神经网络的输入取 4 个比值, $x = (x_1, x_2, x_3, x_4)^T$, 第 1 层共有 4 个节点. 第 2 层的作用函数分别取为 $m_1 = e^{-0.693(x_1-2)^2}$, $m_2 = e^{-0.693x_2}$, $m_3 = 1 - e^{-0.231x_3}$, $m_4 = -e^{-1.368x_4}$. 在神经网络的第 3 层, 我们采用前面描述的粗糙集规则提取算法提取 36 条规则($\mu \geq 0.7$). 然后随机取 300 组数据进行训练, 从剩余的数据中取 300 组进行验证, 结果如表 3 所示. 从表可以看出, 粗糙集神经网络的诊断正确率达到 90.0%, 而计算量远远小于普通神经网络. 从而, 验证本文提出的变压器故障诊断方法的有效性.

表 3 粗糙神经网络和普通神经网络的诊断结果比较

故障类型	验证样本数	普通神经网络			粗糙神经网络		
		训练迭代次数	正确率/(%)	总正确率/(%)	训练迭代次数	正确率/(%)	总正确率/(%)
2	25		80.8			92.0	
3	33		78.8			90.1	
4	21		71.4			85.7	
5	16	593	75.0	78.7	46	87.5	90.0
6	25		72.0			88.0	
8	41		80.5			92.7	
9	56		85.7			89.3	
11	23		73.9			91.3	

4 结束语

本文提出了一种规则提取的神经网络模型. 该模型通过粗糙集理论分析数据, 约简冗余数据, 提取一定置信度的规则. 在这些规则的基础上, 通过神经网络权值调整建立精确映射. 大量的变压器故障诊断实例表明, 本文提出的智能互补变压器诊断策略比普通神经网络诊断的计算速度快的多, 而且诊断正确率高.

参 考 文 献

1 Chen Anpin, Lin Changchun. Fuzzy approaches for fault diagnosis of transformers[J] . Fuzzy Sets and Systems, 2001, 118(1): 139 ~ 151

2 束洪春,孙向飞,司大军. 电力变压器故障诊断专家系统知识库建立和维护的粗糙集方法[J]. 中国电机工程学报, 2002, 22(2): 31~ 35

3 Zhang Y. An artificial new network approach to transformer fault diagnosis[J]. IEEE Transactions on Power Delivery, 1996, 11(4): 1 836~ 1 841

4 Lin Weisong, Hung Chinpao, Wang Manghui. CMAC based fault diagnosis of power transformers[J]. Proceedings of the International Joint Conference on Neural Networks, 2002, 1(1): 986~ 991

5 王 源,胡寿松,齐俊伟. 自组织模糊 CMAC 神经网络及其非线性系统辨识[J] . 航空学报, 2001, 22(6): 556~ 558

6 Carbonara J, Lynch M, Hunt M, et al. Transformer gas analyzer: A practical expert system for the diagnosis of operational faults in electrical transformers[J]. Proceedings of the American Power Conference, 1994, 56(1): 342~ 347

Rough Set-Based CMAC Neural Network for Fault Diagnosis

Feng Yuanjing Li Liangfu Feng Zuren

(Inst. of System Eng., Xi'an Jiaotong Univ., 710049, Xi'an, China)

Abstract A rough set based CMAC neural network is put forward as intelligent complementary and blending tactics of diagnosis. This tactics carry out data compaction on data samples and extract initial diagnostic rule by using rough set theory. To carry out rough mapping on the initial diagnostic rule through neural network and to use the sort approximation ability of neural network, an exact mapping from space of fault state to space of diagnosis is established by which convergence rate and approximation accuracy are greatly improved. This neural network is applied to the example of fault diagnosis of transformer. The result shows that the neural network is strong in sort approximation ability and small in workload of computation and high in rate of correct diagnosis, as compared with that of conventional neural network.

Keywords rough set, neural network, fault diagnosis, transformer