

文章编号: 1000-0887(2006) 01-0089-09

基于知识的模糊神经网络的 旋转机械故障诊断*

李如强, 陈 进, 伍 星

(上海交通大学 振动、冲击、噪声国家重点实验室, 上海 200030)

(朱金福推荐)

摘要: 提出了一种基于知识的模糊神经网络并用于故障诊断。首先基于粗糙集对样本数据进行初步规则获取, 并计算规则的依赖度和条件覆盖度, 然后根据规则数目进行模糊神经网络结构部分设计, 规则的依赖度和条件覆盖度用于设定网络初始权重, 而用遗传算法对神经网络输出参数进行优化。这样的模糊神经网络称为基于知识的模糊神经网络。使用该网络对旋转机械常见故障进行诊断, 结果表明, 和一般模糊神经网络相比, 该网络具有训练时间短而诊断率高的特点。

关键词: 旋转机械; 故障诊断; 粗糙集; 模糊集; 遗传算法; 基于知识的模糊神经网络

中图分类号: TP206.3 文献标识码: A

引 言

众多旋转机械运行在恶劣的环境中, 如剧烈的冲击、振动、高温、摩擦和灰尘, 精确地监测其运行状态是十分必要的, 所以, 旋转机械的故障监测、识别和诊断成为迅速发展的研究领域。目前, 振动分析法^[1]成为旋转机械故障监测和诊断中一个广泛应用而卓有成效的方法。对旋转机械常见故障的分类问题, 一般通过以下 4 步^[2], 即振动信号的测量、信号处理、特征抽取和故障识别。对振动的分析可以通过时域方法和频域方法。时域方法能够了解振动的本质, 但在多峰值振动信号的情况下, 这种方法是不可行的。而频域方法, 包括幅值谱和功率谱方法, 在振动分析中得到更广泛的应用。

在振动信号谱分析的基础上, 可以通过模式匹配或模式识别的方法进行故障诊断。然而, 应用人工智能技术可以进行更深入的故障诊断研究。在人工智能技术中, 神经网络和模糊神经网络^[3]得到了广泛的关注。近年来, 粗糙集理论^[4]也成为一种故障诊断工具, 并成功地应用于电力系统故障诊断^[5]、机车传动系统故障诊断^[6]、柴油机喷油系统故障诊断^[7]。一些综合技术也开始用于故障诊断, 如综合粗糙集理论和神经网络或模糊神经网络技术进行故障诊断。人工神经网络具有优越的非线性模式分类性能和强大的自组织、自学习、联想记忆、分布式并行信息处理和泛化能力; 模糊集合理论能够处理语言变量和模糊的数据, 基于模糊集合

* 收稿日期: 2004_10_11; 修订日期: 2005_08_23

基金项目: 国家“十五”科技攻关计划重点资助项目(2001BA204B05_KHKZ0009)

作者简介: 李如强(1973—), 男, 山东人, 讲师, 博士(联系人, E-mail: rqli163@163.com)。

理论的诊断在一定程度上模拟了人类的思维方法,能够利用多因素进行诊断,但其缺点是模糊隶属函数、模糊规则和模糊算法很难根据实际系统来准确得到。模糊神经网络具有神经网络和模糊集合的优点,但对基于输入输出模糊化的神经网络,和一般神经网络一样,仍存在网络隐层节点数目难以确定的问题,而模糊参数的选择也需要人工干预,而这些在一定程度上影响着基于模糊神经网络故障诊断的正确分类率的高低。粗糙集理论具有知识获取方面的优势,目前仅能处理离散数据,因此现实数据的离散化消除了知识的冗余性,使得基于粗糙集理论获取的知识冗余性较低,从而决定其没有很好的知识泛化能力。遗传算法^[8]是建立在“物竞天择、优胜劣汰”的自然选择基础上的概率型搜索方法,具有其固有的信息并行处理能力和较好的全局搜索性能。因此,本文充分利用粗糙集理论、模糊集合理论、人工神经网络和遗传算法的优势,弥补它们的不足,进行旋转机械故障诊断。

1 粗糙集理论

1.1 粗糙集理论和规则获取

粗糙理论^[4]建立在概念的分类机制基础之上,是波兰数学家 Pawlak 提出的一种分析数据的数学理论。一个知识表达系统可表达为:

$$S = (U, A, V, f),$$

其中, U 为非空有限元素组成的论域, A 为非空有限属性集合, $A = C \cup D$, 子集 C 和 D 分别称为条件属性和决策属性集合, $C \cap D = \Phi$, $V = \bigcup_{a \in A} V_a$ 是属性值的集合, V_a 表示属性 $a \in A$ 的范围, 对 $x \in U, a \in A$, 存在信息函数 $f: U \times A \rightarrow V_a$ 使 $f(x, a) \in V_a$ 。这种描述方式使得知识表达系统可以用二维表格来表示, 称为决策表。

$B \subseteq A$ 在 U 上的不可分辨关系定义为:

$$IND(A) = \{ (x, y) \in U^2 \mid \forall a \in A, f(x, a) = f(y, a) \}.$$

对决策表 S , 设 $U = \{x_1, x_2, \dots, x_m\}$, $C = \{a_1, a_2, \dots, a_n\}$, 则 $m \times m$ 维的分明矩阵^[9]中的每一项为:

$$c_{ij} = \begin{cases} a, & \text{当 } f(x_i, a) \neq f(x_j, a) \text{ 且 } f(x_i, D) \neq f(x_j, D), & a \in C, \\ \phi, & \text{当 } f(x_i, a) \neq f(x_j, a) \text{ 且 } f(x_i, D) = f(x_j, D), & a \in C, \end{cases} \quad i, j = 1, 2, \dots, m, \quad (1)$$

设属性 $a_i, i = 1, 2, \dots, n$ 的属性值为 $v_i, i = 1, 2, \dots, n$, 则分辨函数为:

$$f(v_1, v_2, \dots, v_n; D) = \bigwedge \left\{ \bigvee c_{ij}: 1 \leq j < i \leq m, c_{ij} \neq \right\}, \quad (2)$$

其中, \vee 和 \wedge 分别为析取和合取符号。

对知识表达系统的分类而言,并非所有的条件属性都是必要的。约简就是在不丢失信息的前提下,简单地表示决策属性对条件属性集合的依赖和关联。基于粗糙集的规则获取可以看作一个知识表达、属性简化、属性值简化和规则导出的过程。本文基于参考文献[10]对知识表达系统进行启发式约简,获得决策规则。

1.2 规则的依赖度和条件覆盖度

为了满足故障诊断规则获取的情况,设决策表 S 的决策属性值各不相同,即 $D = \{d_t\}$, $f(x, \{d_t\}) \neq f(x, \{d_j\})$, 其中 $t = 1, 2, \dots, m, 1 \leq i, j \leq m, m$ 表示对象的个数,按照(1)和(2)式构造决策表的分明矩阵和分辨函数。对决策表 S 的第 i 个对象 $x_i, 1 \leq i \leq m$, 得到决策规则

R^i : 当 $f(x, a_1) = v_1^i$ 且 $f(x, a_2) = v_2^i, \dots$ 且

$$f(x, a_j) = v_j^i \text{ 则 } f(x, D) = d_k^i, c = H_i, \quad (3)$$

其中, $v_j^i, d_k^i \in V_a, i, k = 1, 2, \dots, m; j = 1, 2, \dots, n, c$ 表示规则强度, H_i 为规则强度值, $H_i \in [0, 1]^*$. 设 $B^i = \{b_1^i, b_2^i, \dots, b_j^i\}$, 为规则 R^i 的条件属性集合, 则决策属性 $\{d_i\}$ 对条件属性集合 B^i 的依赖度定义为:

$$\gamma^i = \frac{\text{card}(\text{Pos}_{B^i}(\{d_i\}))}{\text{card}(U)}, \quad (4)$$

其中, $\text{card}(\cdot)$ 表示集合的势, $\text{Pos}_{B^i}(\{d_i\})$ 表示 $\{d_i\}$ 的 B^i 正域, 定义函数

$$N_{B^i}^i = \|B^i\|, \quad 1 \leq i \leq n, \quad (5)$$

其中 $\|\cdot\|$ 表示取 \wedge 的数目, $N_{B^i}^i$ 表示规则 R^i 中条件属性 B^i 的数目, 则规则 R^i 关于 $b_j^i, 1 \leq j \leq n$ 的条件覆盖度定义为:

$$O^i(B^i, b_j^i) = \frac{\gamma^i}{N_{B^i}^i}, \quad 1 \leq i \leq m, 1 \leq j \leq n. \quad (6)$$

2 神经网络的构造、配置和优化

2.1 神经网络

选择一种 5 层的前向式神经网络, 如图 1 所示, 其中第 I、II 层分别为输入层和模糊化层, 第 III、IV 层分别为规则的条件层和结论层, 第 V 层为反模糊化层。

对模糊化层, 选择区间在 $[0, 1]$ 上的 π 集模糊隶属函数^[11]

$$\pi(F_i, C, \lambda) = \begin{cases} 2(1 - |F_i - C|/\lambda)^2, & M/2 \leq |F_i - C| \leq \lambda \\ 1 - 2(|F_i - C|/\lambda)^2, & 0 \leq |F_i - C| \leq M/2 \\ 0, & \text{其它} \end{cases} \quad (7)$$

其中, C, λ 分别为语义变量或模糊数据的中心和半径, 如图 2 所示。设神经网络有 l 个输出神经元, 对于 c_k 类输入, 其目标输出矢量为 $O_k = [o_{k,1}, o_{k,2}, \dots, o_{k,k-1}, o_{k,k}, o_{k,k+1}, \dots, o_{k,l}]$, 其中, $o_{k,j} = 0, j \neq k; o_{k,j} = 1, j = k$ 。设训练输出矢量为 $O_p = [o_{p,1}, o_{p,2}, \dots, o_{p,l}]$, 与第 c_k 类的距离表示为:

$$d_{pk} = \sqrt{\sum_{i=1}^l (o_{p,i} - o_{k,i})^2}, \quad (8)$$

则训练输出矢量 O_p 对第 c_k 类的在 $[0, 1]$ 之间的隶属度定义为:

$$\mu_k(O_p) = 1/(1 + (d_{pk}/f_d)^{f_e}), \quad (9)$$

其中, f_d, f_e 为模糊调节因子。

2.2 初步规则获取

设在 m 个输入矢量中, 第 t 个 n 维输入矢量为 $I_t = [F_{t,1}, F_{t,2}, \dots, F_{t,n}]$, 则 m 个 n 维输入矢量构成了 $m \times n$ 的输入矩阵。对于第 i 个列矢量的数据, 即第 i 个诊断特征 F_i , 按递增方向进行排序, 设 $M_{m,i}, F_{\max,i}, F_{\min,i}$ 分别为 F_i 特征的均值、最大值和最小值, $M_{l,i}, M_{h,i}$ 分别为区间 $[F_{\min,i}, C_{m,i}), (C_{m,i}, F_{\max,i}]$ 中数据的均值, 则特征 F_i 的高、中、低的中心和半径定义为

$$\begin{cases} C_{m,i} = M_{m,i}, C_{l,i} = M_{m,i}, C_{h,i} = M_{h,i}, \\ \lambda_{h,i} = C_{m,i} - C_{l,i}, \lambda_{h,i} = C_{h,i} - C_{m,i}, \lambda_{m,i} = (C_{h,i} - C_{m,i})/2. \end{cases} \quad (10)$$

用(7)式和(10)式对 m 个 n 维输入矢量进行模糊化, 得到 $m \times 3n$ 维的模糊矩阵。




图1 神经网络结构




图2 模糊隶属函数

利用 $m \times 3n$ 维的模糊矩阵和 m 个故障类型值进行基于粗糙集的规则获取。设故障类型的数目和故障类型 c_k 的矢量数目分别为 N_F 和 k_m , 则 k_m 个矢量形成 $k_m \times 3n$ 的模糊矩阵。采取阈值 T_{C_k} 对矩阵进行离散化, 即对矩阵中的任一项, 若其值大于 T_{C_k} , 设为 1, 否则为 0, 则得到 $k_m \times 3n$ 离散矩阵。设故障类型 c_k 的故障值为 d_k , 把 k_m 个 3 维的离散值看作决策表的条件属性值, k_m 个故障值 d_k 看作决策表的决策属性值, 就形成决策表 T_k , 这里对象的数目为 k_m , 所有的决策属性值都相同。对决策表 T_k , 设条件属性为 C_k , 建立对象的等价类 $[x_i]_{C_k}$, $1 \leq i \leq k_m$, 若 x_m , $1 \leq m \leq k_m$, 满足 $\max(\text{card}([x_m]_{C_k}))$ 其中, $\text{card}(\cdot)$ 表示集合的势, $\max(\cdot)$ 表示取最大, 则选择对象 x_m 作为决策表 T_k 的代表对象。

对每一个故障类型的样本, 按上述方法获取其对应决策表的代表对象, 把这些对象放到一个决策表中, 就形成了要获取规则的决策表。设该决策表的条件属性为 C , 决策属性为 $\{d_k\}$, 根据参考文献[10]中的启发式约简方法对该决策表进行约简, 得到决策表 T_r 。对该决策表进行规则获取, 规则的表达式如(3)式。并按(4)式、(5)式、(6)式计算规则的依赖度和结论覆盖度。

2.3 神经网络的构造和配置

按如下方式对图1的神经网络进行构造和配置。网络的输入和输出层节点数目分别为诊断特征数目和故障的类型数目, 第II层对第I层的输入进行高、中、低3段模糊化。第III层节点的数目为规则的数目, 第IV层节点的数目和第V层相同, 为故障类型的数目。第II和III之间的连接权重表达规则的前件, 第III和IV层之间的权重表达规则的后件。我们用第III层的第 i 个神经元来表达第 i 条规则, 第 i 个神经元的输出唯一地和第IV层的一个神经元相联, 表达规则 R^i 的后件, 其连接初始权值为第 i 条规则 R^i 的依赖度 v^i 。在第II层中, 只有在规则 R^i 中出现的属性才和第III层的第 i 个神经元相连, 其连接权值为规则的条件覆盖度。在决策表中, 若某一属性 $b_j^i \in B^i$ 的离散值为 1, 则该属性对应的神经元和第III层的第 i 个神经元的连接权值为, $O^i(B^i, b_j^i)$, $1 \leq i \leq m$, $1 \leq j \leq n$, 若为 0, 则为 $-O^i(B^i, b_j^i)$, $1 \leq i \leq m$, $1 \leq j \leq n$ 。网络第II和III层和第III层和第IV层之间其它的连接为 $[0, 0.01]$ 之间的随机数。这样, 就构造了基于粗糙集规则和含有初始权重的模糊神经网络, 即基于知识的模糊神经网络。

2.4 模糊调节因子的优化

选择遗传算法^[8]对基于知识的模糊神经网络的输出参数 f_d 和 f_e 进行优化, 分别选择 8 位

的二进制串对上述参数进行编码,则个体位串数为 $16 \cdot$ 初始群体数,单点交叉,交叉概率和变异概率分别为 50, 0.8 和 0.01, 适应度函数由(9)式确定。

3 实验及诊断结果

3.1 故障样本的获取

考虑旋转机械的如下故障,不平衡、径向碰磨、油膜涡动和轴裂纹。为了便于叙述,把正常状态也看作一种故障。在 Bently 转子试验台上的恒定转速下模拟这 5 种故障。在试验台的水平和垂直方向上分别采集 100、100、240、160 和 200 组数据,每组 4 096 点,采样频率为 2.560 kHz。对每种故障样本,随机的选取 1/2 样本数据作为网络的训练样本和测试样本。

表 1 训练样本中关于 5 种故障的一组征兆

	0~ 0.39fr	0.40~ 0.49 fr	0.5 fr	0.51~ 0.99 fr	1 fr	1.5 fr
正常	0.021 078	0.005 169	0.000 634	0.099 639	0.554 049	0.000 421
不平衡	0.018 861	0.005 207	0.000 721	0.054 279	0.629 339	0.000 234
径向碰磨	0.080 558	0.012 715	0.001 270	0.172 561	0.390 659	0.000 399
油膜涡动	0.051 150	0.158 821	0.017 531	0.341 189	0.070 861	0.001 972
轴裂纹	0.026 101	0.011 949	0.004 176	0.088 991	0.100 204	0.005 173
	2 fr	3 fr	3~ 5 fr	odl fr	5~ 10 fr	
正常	0.024 612	0.014 019	0.048 096	0.022 096	0.121 809	
不平衡	0.004 016	0.002 940	0.060 398	0.004 855	0.161 850	
径向碰磨	0.042 751	0.015 978	0.054 664	0.023 051	0.117 802	
油膜涡动	0.004 844	0.000 701	0.055 509	0.001 885	0.092 260	
轴裂纹	0.156 866	0.008 832	0.068 555	0.013 255	0.083 852	

表 2 输入特征离散化后的决策表

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
正常	0	1	0	1	1	0	1	1	0	1	0	0	0	0	1	0	0
不平衡	0	1	0	1	0	0	1	1	0	0	0	0	1	0	0	1	0
径向碰磨	0	1	0	0	0	0	0	1	0	0	0	1	1	0	0	0	1
油膜涡动	1	0	0	1	0	0	1	1	0	1	0	0	1	0	0	0	1
轴裂纹	1	0	0	1	0	0	1	1	0	1	0	0	0	0	1	0	0
	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	
正常	0	1	0	0	0	1	0	0	1	0	0	1	0	0	0	0	
不平衡	0	1	0	0	0	0	0	0	1	0	0	0	0	1	0	0	
径向碰磨	0	1	0	0	0	0	0	1	0	0	0	0	0	0	1	0	
油膜涡动	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	
轴裂纹	0	1	0	0	1	0	0	0	1	0	1	0	0	0	0	0	

3.2 征兆的选择和获取

研究表明,旋转机械振动信号的频谱,较为敏感地反映了旋转机械常见故障,因此用谱分析获取的征兆进行故障诊断获得广泛的应用。信号的频谱包括幅值谱和功率谱,都可以用于故障诊断。这里考虑 Sawyer^[12]的征兆表选择幅值谱进行征兆提取,选择 11 个幅值特征作为征

兆。表 1 列出了上述 5 种故障的一组幅值征兆。图 3 表示了它们之间的关系,可以看出这些征兆之间不是线性可分的。

3.3 基于粗糙集的规则获取和神经网络的构造

对每个故障的训练样本,取阈值 $T_{C_k}, 1 \leq k \leq 5$, 为 0.7, 得到各个故障训练样本的代表对象。由于不平衡有 4 个不同的代表对象, 故得到 4 个不同的决策表。表 2 为其中的一个决策表。

表 3 约简后的决策表

	(1) L_1	(10) L_4	(17) M_6	$\{d_i\}$
x_1	0	1	0	1
x_2	0	0	0	2
x_3	0	0	1	3
x_4	1	1	1	4
x_5	1	1	0	5

对决策表 2 进行启发式简化, 得到表 3 的简化决策表。决策表中各对象的分辨函数分别为:

$$f^1(x_1, \{d_1\}) = L_1 \wedge L_4, \quad (11)$$

$$f^2(x_2, \{d_2\}) = L_4 \wedge M_6, \quad (12)$$

$$f^3(x_3, \{d_3\}) = M_6 \wedge L_1 + M_6 \wedge L_4, \quad (13)$$

$$f^4(x_4, \{d_4\}) = M_6 \wedge L_1 + M_6 \wedge L_4, \quad (14)$$

$$f^5(x_5, \{d_5\}) = L_1 \wedge M_6. \quad (15)$$

对对象 x_3 和 x_4 , 分别得到 2 条规则

$$f_1^3(x_3, \{d_3\}) = M_6 \wedge L_1, \quad (16)$$

$$f_2^3(x_3, \{d_3\}) = M_6 \wedge L_4, \quad (17)$$

$$f_1^4(x_4, \{d_4\}) = M_6 \wedge L_1, \quad (18)$$

$$f_2^4(x_4, \{d_4\}) = M_6 \wedge L_4. \quad (19)$$

对式 (11)、式 (12)、式 (15)、式 (16) ~ 式 (19) 计算规则的依赖度和条件覆盖度, 分别为:

$$\gamma^1 = 0.2, \quad O^1(L_1 \wedge L_4, L_1) = -0.1, \quad O^1(L_1 \wedge L_4, L_4) = 0.1,$$

$$\gamma^2 = 0.6, \quad O^2(L_4 \wedge M_6, L_4) = -0.3, \quad O^2(L_4 \wedge M_6, M_6) = -0.3,$$

$$\gamma_1^3 = 0.6, \quad O_1^3(M_6 \wedge L_1, M_6) = 0.3, \quad O_1^3(M_6 \wedge L_1, L_1) = -0.3,$$

$$\gamma_2^3 = 0.6, \quad O_2^3(M_6 \wedge L_4, M_6) = 0.3, \quad O_2^3(M_6 \wedge L_4, L_4) = -0.3,$$

$$\gamma_1^4 = 0.6, \quad O_1^4(M_6 \wedge L_1, M_6) = 0.3, \quad O_1^4(M_6 \wedge L_1, L_1) = 0.3,$$

$$\gamma_2^4 = 0.6, \quad O_2^4(M_6 \wedge L_4, M_6) = 0.3, \quad O_2^4(M_6 \wedge L_4, L_4) = 0.3,$$

$$\gamma^5 = 0.6, \quad O^5(L_1 \wedge M_6, L_1) = 0.3, \quad O^5(L_1 \wedge M_6, M_6) = -0.3,$$

然后根据规则的数目、规则的依赖度和条件覆盖度构造和配置神经网络, 如图 4 所示。

3.4 实验结果

对基于知识的模糊神经网络和一般模糊神经网络, 我们比较了它们的分类能力及训练时间, 其中, 一般模糊神经网络的结构如图 1 所示。表 4 列出了用不同结构的基于知识的模糊神经网络和一般模糊神经网络对上述 5 种故障进行分类的结果。表 5 给出了用两种网络对每种

故障进行诊断的结果,其中基于知识的模糊神经网络由属性 (L_1, L_4, M_6) 获得的知识初始化的网络,而一般模糊神经网络选择 11_33_10_5_5 的网络结构。表中的训练时间,是指程序进行神经网络的训练时间,其中程序由 C++ 编写,在 PCIV/2.4 GHz/256 MB 的个人计算机上运行。




图 3 关于 5 种故障的一组征兆之间的关系




图 4 神经网络的构造和配置

表 4 不同结构的基于知识的模糊神经网络和一般模糊神经网络对 5 种故障的诊断结果比较

迭代次数	一般模糊神经网络 (%)			基于知识的模糊神经网络 (%)			
	11_33_5_5_5	11_33_10_5_5	11_33_15_5_5	L_1, L_2, L_5	L_1, L_2, L_4	L_1, L_4, M_6	M_1, L_2, L_4
20	65.00	68.75	61.75	92.00	92.00	86.25	92.00
40	80.25	82.25	78.00	91.75	91.75	95.75	91.75
60	84.00	67.75	84.50	95.25	95.25	95.50	95.25
80	84.50	90.50	81.00	86.50	86.50	94.00	86.50
100	90.75	90.75	82.25	94.25	94.25	95.50	94.25
150	78.50	90.50	93.50	95.00	95.00	96.75	95.00
200	75.75	90.00	90.75	92.75	92.75	98.25	92.75
250	90.50	94.25	88.75	95.75	95.75	97.50	95.75
300	74.00	91.00	87.25	95.00	95.00	96.50	95.00
350	87.25	93.75	92.00	96.50	96.50	95.25	96.50
400	93.00	94.25	91.00	85.75	85.75	96.25	85.75
500	71.25	92.00	85.25	96.75	96.75	96.00	96.75
600	70.00	92.25	90.25	92.75	92.75	95.50	92.75

表 4 列出了不同网络结构下对上述 5 种故障进行诊断的比较结果。对一般模糊神经网络而言,具有 11_33_10_5_5 结构的网络要比其它结构的网络有更好的诊断能力。对基于知识的模糊神经网络,由属性集合 (L_1, L_4, M_6) 产生的初始知识配置的网络,较其它网络具有较高的分类能力,并且在不同的训练次数下,分类能力具有更好的稳定性。一般而言,在相同的训练次数下,基于知识的模糊神经网络的性能要优于一般模糊神经网络。

由表 5 可以看出,在对正常和不平衡两种故障的分类能力上,基于知识的模糊神经网络较

一般模糊神经网络有明显的提高。而对于油膜涡动故障, 基于知识的模糊神经网络具有非常好的识别能力, 而一般模糊神经网络在某些情况下能够识别。很显然, 在相同的训练次数下, 对各种故障, 基于知识的模糊神经网络的性能要优于一般模糊神经网络。在分类能力上, 基于知识的模糊神经网络比一般模糊神经网络普遍高 3%, 最高达 13.75%, 同时基于知识的模糊神经网络要有相对少的网络训练时间。

表 5 基于知识的模糊神经网络和一般模糊神经网络的性能比较

	基于知识的模糊神经网络(11_33_7_5_5) (%)					一般模糊神经网络(11_33_10_5_5) (%)				
	迭代次数					迭代次数				
	100	150	200	300	400	100	150	200	300	400
正常	98.00	98.00	100.00	98.00	98.00	64.00	86.00	88.00	92.00	84.00
不平衡	78.00	84.00	94.00	94.00	100.00	70.00	92.00	82.00	66.00	98.00
径向碰磨	95.83	98.33	97.50	92.50	96.67	77.50	90.82	86.67	84.17	80.00
油膜涡动	100.00	100.00	100.00	100.00	100.00	95.00	98.75	100.00	98.75	100.00
轴裂纹	99.00	98.00	99.00	99.00	99.00	93.00	97.00	94.00	90.00	97.00
识别水平	95.50	96.75	98.25	96.50	98.50	82.25	93.50	90.75	87.25	91.00
训练时间(s)	0.328	0.500	0.656	1.000	1.453	0.876	1.328	1.750	2.625	3.579

4 结 论

在综合粗糙集理论、模糊集合理论、人工神经网络和遗传算法技术的基础上, 充分利用这些技术的优势, 弥补它们的不足, 提出了一种基于知识的模糊神经网络。用该网络对旋转机械故障, 如正常、不平衡、径向碰磨、油膜涡动和轴裂纹进行诊断, 诊断分类结果显示, 在训练时间方面, 基于知识的模糊神经网络少于一般模糊神经网络, 而其对测试样本的分类能力则高于后者。同时基于知识的模糊神经网络根据粗糙集获得的规则进行设计, 避免了神经网络设计的盲目性。

[参 考 文 献]

- [1] Renwick J T. Vibration analysis_a proven technique as a predictive maintenance tool [J]. IEEE Transactions on Industry Application, 1985, 21: 324—332.
- [2] Toshio T, Tornoya N, Peng C. Failure detection and diagnosis of rotating machinery by orthogonal expansion of density function of vibration signal [A]. In: Proceedings. Eco Design' 99: First International Symposium On Environmentally Conscious Design and Inverse Manufacturing [C]. Tokyo, Japan: 1999, 86—891.
- [3] 姚洪兴, 赵林度, 盛昭瀚. 基于模糊神经网络的故障诊断方法的应用 [J]. 气轮机技术, 2000, 42(5): 257—262.
- [4] Pawlak Z. Rough sets [J]. International Journal of Information and Computer Science, 1982, 11(5): 341—348.
- [5] OU Jian, SUN Cai_xin, BI Wei_min, et al. A steam turbine_generator vibration fault diagnosis method based on rough set [A]. In: Proceedings of IEEE International Conference on Power System Technology [C]. Kunming, China: 2002, 1532—1534.
- [6] LI Xiao_lei, WU Xiao_bing. The application of rough set theory in vehicle transmission system fault diagnosis [A]. In: Proceedings of IEEE International Conference on Vehicle Electronics [C].

- Changchung, China: 1999, 240—242.
- [7] CAO Long_han, CAO Chang_xiu, GUO Zhen, et al. The research of fault diagnosis for fuel injection system of diesel engine with ANN based on rough sets theory[A]. In: Proceeding of the 4th World Congress on Intelligent Control and Automation [C]. Shanghai, China: 2002, 410—414.
- [8] 王小平, 曹立明. 遗传算法——理论、应用与软件实现[M]. 西安: 西安交通大学出版社, 2002, 1—38.
- [9] Walczak B, Massart D.L. Rough sets theory[J]. Chemometrics and Intelligent Laboratory Systems, 1999, **47**: 1—16.
- [10] 李如强, 陈进, 伍星. 基于模糊 C 均值聚类和粗糙集理论的旋转机械故障诊断[J]. 信息与控制, 2004, **24**(1): 4—5.
- [11] Mitra S, Mitra P, Pal S K. Evolutionary modular design of rough knowledge- based network using fuzzy attributes[J]. Neurocomputing, 2001, **36**: 45—66.
- [12] Sawyer J. Sawyer's Turbomachinery Maintenance Handbooks [M]. Turbomachinery International Publications, 1980.

Fault Diagnosis of Rotating Machinery Using Knowledge-Based Fuzzy Neural Network

LI Ru_qiang, CHEN Jin, WU Xing

(The State Key Laboratory of Vibration, Shock & Noise, Shanghai Jiaotong University, Shanghai, 200030, P. R. China)

Abstract: A novel knowledge-based fuzzy neural network (KBFNN) for fault diagnosis is presented. Crude rules were extracted and the corresponding dependent factors and antecedent coverage factors were calculated firstly from the diagnostic sample based on rough sets theory. Then the number of rules was used to construct partially the structure of a fuzzy neural network and those factors were implemented as initial weights, with fuzzy output parameters being optimized by genetic algorithm. Such fuzzy neural network was called KBFNN. This KBFNN was utilized to identify typical faults of rotating machinery. Diagnostic results show that it has those merits of shorter training time and higher right diagnostic level compared to general fuzzy neural networks.

Key words: rotating machinery; fault diagnosis; rough sets theory; fuzzy sets theory; generic algorithm; knowledge-based fuzzy neural network